

ALZIR FELIPPE BUFFARA ANTUNES

**CLASSIFICAÇÃO DE AMBIENTE CILIAR BASEADA EM  
ORIENTAÇÃO A OBJETO EM IMAGENS DE  
ALTA RESOLUÇÃO ESPACIAL**

Tese apresentada ao Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do grau e título de Doutor em Ciências Geodésicas.

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Christel Lingnau

Co-orientador: Prof. Dr. Jorge Centeno

CURITIBA

2003

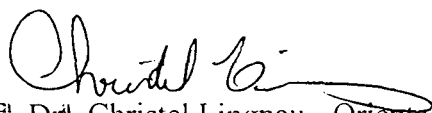
**“CLASSIFICAÇÃO DE AMBIENTE CILIAR BASEADA EM  
ORIENTAÇÃO A OBJETO EM IMAGENS DE ALTA  
RESOLUÇÃO ESPACIAL”**

**POR**

**ALZIR FELIPPE BUFFARA ANTUNES**

Tese nº 027 aprovada como requisito parcial do grau de Doutor no  
Curso de Pós-Graduação em Ciências Geodésicas da Universidade  
Federal do Paraná, pela Comissão formada pelos professores:

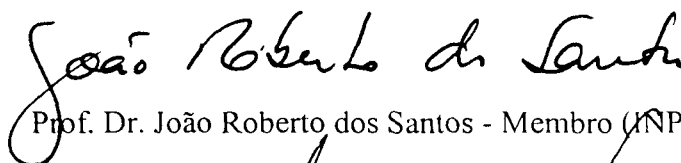
Curitiba, 10 de março de 2003.



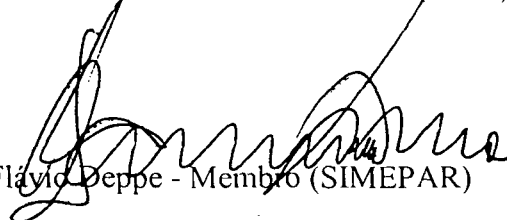
Profª. Drª. Christel Lingnau - Orientadora e Presidente (UFPR)



Prof. Dr. Hans Peter Bähr – Membro (Universidade de Karlsruhe)



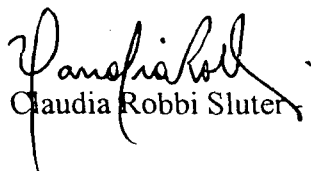
Prof. Dr. João Roberto dos Santos - Membro (INPE)



Eng. Dr. Flávio Deppe - Membro (SIMEPAR)



Prof. Dr. Hélio Pedrini – Membro (UFPR)



Profª. Drª. Claudia Robbi Sluter, Membro (UFPR)

*Aos meus pais,  
Zico e Futin.*

## AGRADECIMENTOS

Gostaria de expressar meus sinceros agradecimentos as seguintes instituições:

- Ao Paraná 12 meses pela disponibilização dos dados sobre a região de Nova Esperança-Pr;
- A Coordenação do Curso de Pós Graduação em Ciências Geodésicas pelo apoio institucional;
- IPF, Institut für Photogrammetrie und Fernerkundung, Universität Karlsruhe, Alemanha pelo suporte técnico;
- CAPES e coordenação do Projeto UNIBRAL (UFPR), por possibilitar o intercâmbio com a Universidade de Karlsruhe;
- EMATER, Nova Esperança pelo apoio de campo.

Aos colegas e profissionais cujo conhecimento e dedicação foram fundamentais para consecução deste trabalho:

- Profa. Dra. Christel Lingnau, orientadora, Departamento de Ciências Florestais, UFPR;
- Prof. Dr. Jorge Centeno da Silva, co-orientador, Departamento de Geomática, UFPR;
- Ao geógrafo Prof. Luiz Rego (FELIS), Universität Freiburg, pelo suporte técnico;
- A André Luiz pelo apoio e revisão do texto;
- Colega e amiga Professora Selma Regina Aranha pela leitura criteriosa do texto;
- À minha mãe Profa. Dra. Futin Buffara Antunes pelo apoio logístico.

Um agradecimento especial a minha família, e, sobretudo a Deus, sob intercessão de Nossa Senhora do Rocio, pela graça de ter tido paz e saúde para concluir este trabalho.



## SUMÁRIO

<b>AGRADECIMENTOS .....</b>	<b>III</b>
<b>SUMÁRIO .....</b>	<b>IV</b>
<b>LISTA DE FIGURAS.....</b>	<b>V</b>
<b>LISTA DE TABELAS .....</b>	<b>VI</b>
<b>LISTA DE ANEXOS .....</b>	<b>VII</b>
<b>RESUMO .....</b>	<b>VIII</b>
<b>ABSTRACT .....</b>	<b>IX</b>
<b>1- INTRODUÇÃO .....</b>	<b>10</b>
1.1- MOTIVAÇÃO.....	12
1.2- OBJETIVOS.....	13
<b>2- CARACTERÍSTICAS DA ÁREA DE ESTUDO .....</b>	<b>15</b>
2.1- LOCALIZAÇÃO.....	15
2.2- CARACTERÍSTICAS FITOGEOGRÁFICAS DA REGIÃO .....	15
2.3- DESCRIÇÃO DAS CLASSES DE USO E COBERTURA DA TERRA .....	20
2.4- MATERIAL E DADOS DISPONÍVEIS .....	21
<b>3- REVISÃO DA LITERATURA .....</b>	<b>23</b>
3.1- COGNIÇÃO E SEMÂNTICA.....	23
3.2- INTERPRETAÇÃO DA IMAGEM .....	25
3.3- SEGMENTAÇÃO.....	27
3.3.1- Segmentação orientada a regiões .....	29
3.3.2 - Segmentação Multi-resolução.....	30
3.4- ANÁLISE ORIENTADA A OBJETO .....	33
3.5- LÓGICA FUZZY .....	35
3.6- CLASSIFICAÇÃO.....	41
3.6.1-Inserção do contexto .....	43
3.6.2- Regras fuzzy .....	43
3.7- REDE SEMÂNTICA .....	45
<b>4- METODOLOGIA.....</b>	<b>47</b>
4.1- SEGMENTAÇÃO DA IMAGEM.....	47
4.2- DESCRIÇÃO DO CONHECIMENTO .....	53
4.2.1- Modelo Conceitual.....	55
4.2.2- Interpretação da Imagem.....	58
4.2.3- Rede Semântica.....	61
4.3- CLASSIFICAÇÃO.....	68
4.3.1- Classificação fuzzy ao nível de pixel.....	68
4.3.2- Classificação ao nível dos objetos- Regras Fuzzy .....	72
4.3.3- Descritores .....	74

4.4- CONFIABILIDADE DA CLASSIFICAÇÃO.....	79
4.4.1- Ambigüidade da Classificação.....	80
4.4.2- Potencial de Discriminação .....	84
4.4.3- Coeficiente de Contingência Cramer's V .....	85
4.4.4- Divergência Transformada .....	86
<b>5- RESULTADOS E DISCUSSÕES .....</b>	<b>87</b>
5.1- INTERPRETAÇÃO VISUAL DA IMAGEM NOS TRÊS DOMÍNIOS.....	87
5.2- RESULTADOS DA CLASSIFICAÇÃO AO NÍVEL DE PIXEL.....	89
5.2.1- Máxima Verossimilhança (maxver).....	90
5.2.2- Classificação fuzzy .....	92
5.3- SEGMENTAÇÃO .....	95
5.3.1- Discriminação das Classes.....	98
5.4- CLASSIFICAÇÃO.....	101
5.4.1- Parâmetros descritores .....	102
5.4.2- Métodos de Classificação baseada em objeto.....	104
5.6.1- Determinação do potencial de discriminação .....	112
5.6.2- Coeficiente Tau de concordância.....	113
5.6.3- Ambigüidades .....	115
5.6.4- Coeficiente de Correlação.....	117
5.7- ANÁLISE DA APLICABILIDADE DA REDE SEMÂNTICA PARA UMA OUTRA ÁREA .....	118
5.8- ANÁLISE COMPARATIVA ENTRE A CLASSIFICAÇÃO BASEADA EM OBJETOS E A FOTOINTERPRETAÇÃO .....	119
<b>6- CONCLUSÕES E RECOMENDAÇÕES .....</b>	<b>123</b>
6.1- CONCLUSÕES.....	123
6.2- SUGESTÕES E RECOMENDAÇÕES.....	125
<b>GLOSSÁRIO.....</b>	<b>127</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>129</b>

## LISTA DE FIGURAS

FIGURA 1: LOCALIZAÇÃO DA ÁREA DE ESTUDO. ....	15
FIGURA 2- MATA DE GALERIA E VÁRZEA. ....	17
FIGURA 3- IMAGEM IKONOS SOBREPOSTA AO MDT .....	18
FIGURA 4- REMANESCENTE DO AMBIENTE CILIAR.....	19
FIGURA 5- RELAÇÕES TOPOLÓGICAS DE POLÍGONOS.....	34
FIGURA 6- FUNÇÃO DE PERTINÊNCIA DE UM CONJUNTO FUZZY .....	37
FIGURA 7- FUNÇÃO DE PERTINÊNCIA FUZZY E PERTINÊNCIA ABRUPTA .....	38
FIGURA 8- FUNÇÃO DE PERTINÊNCIA SIGMOIDAL.....	39
FIGURA 9- SEGMENTAÇÃO HIERÁRQUICA (MULTI-RESOLUÇÃO).....	53
FIGURA 10- ESTRUTURA DO DADO ESPACIAL .....	55
FIGURA 11- RELAÇÕES ENTRE CLASSES, OBJETOS E ATRIBUTOS.....	56

FIGURA 12- MODELO CONCEITUAL DA CLASSIFICAÇÃO ORIENTADA A OBJETO.....	57
FIGURA 13- DOMÍNIOS DE INTERPRETAÇÃO.....	58
FIGURA 14- PERCEPÇÃO ASSOCIATIVA E SELETIVA BASEADA NA FORMA E COR DOS OBJETOS.....	60
FIGURA 15- LIGAÇÕES ENTRE OS NÓS.....	62
FIGURA 16- NÍVEIS HIERÁRQUICOS- ESTRUTURA SEMÂNTICA.....	67
FIGURA 17- PARTIÇÃO DO ESPAÇO ESPECTRAL E SUPERFÍCIES DE DECISÃO.....	70
FIGURA 18- EXEMPLO DE GRAUS DE PERTINÊNCIA.....	73
FIGURA 19- PARÂMETRO DE FORMA BASEADO NA GEOMETRIA.....	76
FIGURA 20- GRÁFICOS DE AMBIGÜIDADE.....	83
FIGURA 21- COMPARAÇÃO DA CLASSIFICAÇÃO FUZZY E MAXVER DE UMA PARTE DA IMAGEM.....	93
FIGURA 22- GRAUS DE INCERTEZA PARA A CLASSE: FLORESTA.....	94
FIGURA 23- IMAGENS SEGMENTADAS COM DIFERENTES FATOR ESCALA.....	96
FIGURA 24- AS AMOSTRAS DE OBJETOS.....	98
FIGURA 25- DESCRITORES DE ASSIMETRIA E MÉDIA ESPECTRAL.....	99
FIGURA 26- RELAÇÕES DE CONTEXTO, RIO, MATA DE GALERIA E VÁRZEA.....	100
FIGURA 27- GRÁFICO DE TEXTURA. BASEADO NOS VALORES MÉDIOS DE ASSIMETRIA.....	101
FIGURA 28- FUNÇÃO DE PERTINÊNCIA FUZZY BASEADO EM VALORES DE DENSIDADE.....	104
FIGURA 29- GRUPOS SEMÂNTICOS.....	106
FIGURA 30- CLASSIFICAÇÃO BASEADA NO CONTEXTO URBANO E RURAL.....	109
FIGURA 31- ESTRUTURA SEMÂNTICA COM AUSÊNCIA DE NÍVEIS HIERÁRQUICOS.....	111
FIGURA 32- ÁREA TESTE MUNICÍPIO DE ATALAIA.....	118
FIGURA 33- COMPARAÇÃO DA CLASSIFICAÇÃO E INTERPRETAÇÃO.....	121

### LISTA DE TABELAS

TABELA 1- CARACTERÍSTICAS DAS CLASSES DE VÁRZEA, AGRICULTURA E MATA DE GALERIA.....	65
TABELA 2- DESCRITORES BASEADOS EM VALORES ESPECTRAIS.....	74
TABELA 3- ÍNDICES DE FORMA.....	77
TABELA 4- RESULTADO DA INTERPRETAÇÃO NOS TRÊS DOMÍNIOS DA IMAGEM, CENA E SEGMENTOS.....	88
TABELA 5- DIVERGÊNCIA TRANSFORMADA PARA AS CLASSES MENOS DISTINGUÍVEIS.....	91
TABELA 6- GRAU DE CONCORDÂNCIA TAU DAS CLASSIFICAÇÕES AO NÍVEL DE PIXEL.....	93
TABELA 7- PARÂMETROS UTILIZADOS NA SEGMENTAÇÃO.....	95
TABELA 8- RELAÇÕES DE INCERTEZA DAS CLASSES BASEADAS NA CLASSIFICAÇÃO FUZZY E DIVERGÊNCIA TRANSFORMADA.....	97
TABELA 9- RELAÇÃO SEMÂNTICA ENTRE OBJETOS E DESCRITORES.....	103
TABELA 10- CLASSIFICAÇÃO POR ESPECIALIZAÇÃO: BASEADA EM HIERARQUIA.....	107

TABELA 11- POTENCIAL DE DISCRIMINAÇÃO PARA AS DIFERENTES CLASSIFICAÇÕES .....	113
TABELA 12- MATRIZ DE ERROS $PO_{+1}$ ACURÁCIA DO PRODUTOR, $P_1$ + ACURÁCIA DO USUÁRIO.....	114
TABELA 13- ÍNDICE TAU DE CONCORDÂNCIA.....	115
TABELA 14- ESTABILIDADE DA CLASSIFICAÇÃO FUZZY BASEADA NA REDE ..	116
TABELA 15- CLASSIFICACAO BASEADA NA REDE SEMANTICA DE OUTRA ÁREA DA IMAGEM.....	119
TABELA 16- COMPARAÇÃO ENTRE OS ELEMENTOS DA FOTOINTERPRETAÇÃO E AS CLASSIFICAÇÕES.....	120
TABELA 17- COEFICIENTE CRAMER PARA A FOTOINTERPRETAÇÃO E IMAGENS CLASSIFICADAS.....	122

### LISTA DE ANEXOS

ANEXO 1- IMAGEM IKONOS E RETIFICAÇÃO.....	140
ANEXO 2- ÍNDICES DE ACURÁCIA .....	142
ANEXO 3- DESCRITORES DOS OBJETOS .....	144
ANEXO 4- SINTAXE DAS REGRAS FUZZY .....	145
ANEXO 5- RESULTADO DA CLASSIFICAÇÃO ORIENTADA A OBJETO .....	146
ANEXO 6- ACURÁCIA DA INTERPRETAÇÃO.....	147

## RESUMO

A classificação baseada em contexto é um importante campo de estudos no processamento digital de imagens. A inserção do conhecimento dentro do processo de classificação da vegetação é uma das formas atualmente utilizadas pela comunidade de sensoriamento remoto a fim de incrementar a qualidade da classificação. O presente estudo é embasado no algoritmo de segmentação multi-resolução, *FNEA* (*fractal net evolution approach*), que permite segmentar uma imagem em diferentes níveis hierárquicos, a inserção do contexto é realizada através de relações entre os objetos. A área de estudo escolhida foi uma área rural no município de Nova Esperança-Pr, onde se pretendeu mapear tipologias vegetais no ambiente ciliar do Rio Paracatu. Com a execução deste trabalho foi possível apresentar uma proposta de classificação digital de imagem de alta resolução baseada em orientação a objeto do ambiente ciliar para a área de estudo adotada. Os objetos oriundos do processo de segmentação multi-resolução permitiram a criação de diferentes níveis de segmentos, o que pode sustentar uma hierarquia entre objetos e subobjetos. Esta hierarquia foi o fundamento para a estruturação de uma rede semântica, baseada no conhecimento. A classificação foi realizada por lógica fuzzy através de descritores de forma, textura e relações entre objetos e subobjetos. Foram avaliadas as diferentes opções de classificação dos objetos, tais como rede hierárquica, o processo seletivo e a mudança de especialista. Analisou-se ainda o grau de detalhamento das classes e subclasses que os diferentes modelos de classificação apresentam (potencial de discriminação). A acurácia da classificação foi baseada nas ambigüidades geradas a partir da classificação fuzzy.

**Palavras-chave:** *Classificação, Orientação a Objeto, Segmentação Multi-resolução, Lógica Fuzzy.*

## ABSTRACT

Context base classification plays an important role in digital image analysis. The insertion of the knowledge base in the digital classification process is one of currently forms used by the community of remote sensing for vegetation mapping, so as end to develop the quality of the classification. Advanced image segmentation techniques (*FNEA: fractal net evolution approach*), was used in this study to provide the context introduction. The tested site was an agricultural area in the city of Nova Esperança-Pr, wherein was mapped the riparian vegetation along the Paracatu River. This work tried to present a proposal for high resolution image classification of the riparian environment based on object oriented analysis. The objects are derived by means of multiresolution segmentation. It allows a creation of different levels of segments supporting a hierarchy structure, generating spatial relations between objects and sub-objects. This hierarchy was the bedding for the semantic network. The knowledge base was the basis of the semantics. The classification was based on fuzzy rules by the means of descriptors such as: form, texture and relations between objects and sub-objects. Different approaches of classification were assessed: semantic network, selective and context change classification. It was also evaluated the degree of detailing of the classes and subclasses in different levels of segmentation (thematic resolution). The analysis of classification accuracy is relied upon ambiguities generated by fuzzy rules.

**Key Words:** *Classification, Object Oriented, Multiresolution Segmentation, Fuzzy Logic.*

## 1- INTRODUÇÃO

Enquanto o sensoriamento remoto teve nas últimas duas décadas um enorme progresso no que se refere à captação de imagens multiespectrais de média e alta resolução espacial, a vasta maioria de aplicações baseia-se em métodos de processamentos desenvolvidos no final dos anos 70. Vários métodos de classificação digital foram aprimorados recentemente (ex.: lógica fuzzy, teoria da evidência, análise de incertezas, etc.), sendo que tal aprimoramento ocorreu em nível de pixel. Quando se considera uma resolução espacial mais alta (de 1 a 4 metros) torna-se provável que um determinado pixel possua características espectrais semelhantes às de seus vizinhos. Desta forma, os algoritmos de classificação podem ser baseados no contexto do pixel, ou seja, considerando-se a vizinhança.

O contexto espacial apresenta um modesto papel quando o processo de classificação considera pixels individuais. Estudos recentes mostram que esta limitação é bem menor quando o agrupamento de pixels vizinhos ou objetos são levados em consideração. O uso de técnicas baseadas em classificação de objetos ao invés de pixels se apresenta como alternativa aos métodos convencionais.

No que se refere à orientação a objetos, cada objeto ou segmento representa uma feição do mundo real. Os objetos passam a possuir propriedades temáticas e geométricas. Desta maneira, o contexto espacial é descrito em termos de relações topológicas entre os objetos.

Analisar uma imagem implica inserir a sua semântica. Em alguns casos a informação semântica para a interpretação da imagem não está presente em um pixel, mas em objetos ou regiões (agrupamento de dois ou mais objetos de características similares) que possuem relações espaciais mútuas.

Ademais, imagens de alta resolução espacial apresentam padrões de textura bem mais evidentes. Em muitos casos, a textura pode estar mais presente em nível de objeto. Tomando, por exemplo, um agrupamento de árvores na imagem Landsat, este pode ser considerado como um objeto homogêneo; porém na mesma área, em imagem de alta resolução espacial (tipo Ikonos), o agrupamento é representado por vários pixels de diferentes tons de cinza, os quais compõem o objeto. Desta forma, objetos homogêneos não são apenas caracterizados por sua assinatura espectral, mas também pela textura.

A classificação digital de imagens orbitais de alta resolução espacial baseada em orientação a objeto permite que se leve em consideração propriedades oriundas do agrupamento de pixels, como forma, textura e brilho. Objetos que possuem propriedades similares podem ser associados à determinada categoria. Tais propriedades embasadas em parâmetros refletem, de certa forma, o contexto e são de fundamental importância na detecção de tipologias florestais. A observação de diferentes formas florestais, considerando conjuntamente parâmetros de textura e forma, parece ser mais adequada do que a simples análise multiespectral.

A segmentação da imagem em diferentes escalas de objetos pode levar à criação de uma rede hierárquica que relaciona objetos maiores a subobjetos (objetos menores) onde o conhecimento pode ser inserido. Uma vez que os objetos ou regiões são contextualizados, o conhecimento do mundo real pode ser realizado por meio de lógica fuzzy através de parâmetros espectrais e parâmetros de forma.

Pretende-se averiguar de que maneira a orientação a objeto pode aperfeiçoar o resultado da classificação e ainda qual a contribuição alcançada no que se refere ao mapeamento do ambiente ciliar. Este ambiente é composto por diferentes tipologias florestais tais como várzea e vegetação de galeria, e sua discriminação é bastante importante no que diz respeito ao manejo florestal. Além disso, a classificação do ambiente ciliar é dependente das relações



espaciais com outras classes que compõem a cena. Estas relações estão baseadas no conhecimento e podem ser representadas por meio de uma estrutura semântica. A classificação contextualizada surge como uma ferramenta importante para incrementar o detalhamento de diferentes feições que constituem a imagem.

## 1.1- MOTIVAÇÃO

Dados de sensoriamento remoto são de utilidade crescente e ininterrupta na geração e atualização de banco de dados espacialmente referenciados. Neste contexto, a extração de feições geográficas de imagens orbitais de alta resolução já se configura como uma das principais fontes de dados em Sistema de Informação Geográfica (GIS), por sua acurácia e atualidade. Contudo, diferentemente dos métodos convencionais de extração de feições baseados em probabilidades de distribuição Gaussiana, as imagens de alta resolução demandam um novo delineamento metodológico. Faz-se mister enfocar de que maneira objetos podem ser mais adequados que pixels individuais no processo de classificação contextualizada.

Uma das razões para a adoção de classificação digital em nível de objetos, proposta neste trabalho, reside no fato de que objetos representam de maneira mais eficaz as feições de uma cena. As relações entre objetos podem, de certa forma, contribuir para inserção do conhecimento.

O método proposto é baseado em *FNEA* (Evolução de Rede Fractal)- implementado definitivamente no ano de 2001 no *software E\_cognition* (Definiens, Alemanha)- que permite criar hierarquia entre objetos e inserir o contexto na classificação digital de imagens. A potencialidade deste tipo de classificação é um avanço tecnológico sem precedentes na área de processamento de imagens, embora a eficiência e aplicabilidade do método a nível de

usuário ainda sejam restritas. Assim sendo, este trabalho pretende contribuir para o uso adequado desta nova tecnologia no quadro de classificação da vegetação, tendo em vista a carência de estudos mais aprofundados nesta tecnologia. Além do mais, a classificação digital com vistas ao monitoramento de ambiente ciliar pode ser útil à ação de conscientização, quer no trato do uso do solo, quer na preservação do meio ambiente.

O mapa temático resultante da classificação orientada a objetos possui uma estrutura de dados gráficos e alfanuméricos de forma a permitir uma melhor manipulação dos dados vetoriais resultantes. Esta metodologia pode contribuir sobremaneira na atualização de banco de dados geográficos que compõe um Sistema de Informação Geográfica. Assim sendo, a obtenção de informação sobre o ambiente ciliar serve como base para sua monitoração e, conseqüentemente, à sua preservação.

## 1.2 - OBJETIVOS

O objetivo geral desta pesquisa é delinear uma metodologia capaz de classificar as tipologias vegetais do ambiente ciliar de uma imagem multiespectral de alta resolução tendo como base princípios de segmentação orientada a objeto e lógica fuzzy.

Os objetivos específicos são os seguintes:

- Avaliar a segmentação multi-resolução baseada na extração de objetos homogêneos considerando parâmetros espectrais e de forma (assimetria, densidade e índice de forma);


- Estruturar uma rede semântica que insira a base do conhecimento dentro do ambiente ciliar;
- Implementar a rede semântica através de estrutura hierárquica orientada a objeto e proceder a classificação por meio de regras fuzzy;
- Comparar o método proposto com os métodos tradicionais de máxima verossimilhança e lógica fuzzy ao nível de pixel para o mapeamento do ambiente ciliar.

## 2- CARACTERÍSTICAS DA ÁREA DE ESTUDO

### 2.1- LOCALIZAÇÃO

A área escolhida para este estudo localiza-se no município de Nova Esperança– PR, Figura 1. A área abrange a bacia Ribeirão do Paracatu a oeste (próximo a BR-376), ao sul com o Ribeirão do Jacupiranga, ao norte com Ribeirão Caxangá, que abastecem de água a região de Nova Esperança. O polígono em verde da Figura 1 mostra a bacia do Rio Paracatu próxima à zona urbana do município. A área teste abrange uma superfície aproximada de 2.406 hectares e 20,10 km de perímetro, medida na imagem retificada.

FIGURA 1: LOCALIZAÇÃO DA ÁREA DE ESTUDO.



### 2.2- CARACTERÍSTICAS FITOGEOGRÁFICAS DA REGIÃO

Segundo KUNIYOSHI & RODERJAN (1987), pouco restou da Floresta Estacional Semidecidual Aluvial que povoava o norte do Estado do Paraná. Este tipo de floresta

compreende as formações florestais das regiões entre 200 e 800 metros de altitude, com florística menos diversificada em relação às formações ombrófilas (RODERJAN et al. 2002). As formações vegetais dessa unidade têm como principal característica fisionômica a semidecidualidade na estação desfavorável.

Com o avanço da fronteira agrícola a partir da década de 30, grandes porções da floresta nativa foram totalmente devastadas. A boa qualidade do solo associada à expansão da cultura cafeeira foi determinante para o quase total desaparecimento da floresta nativa. Segundo RODERJAN et al (2002), esta unidade fitogeográfica foi a mais drasticamente antropizada em todo o Estado.

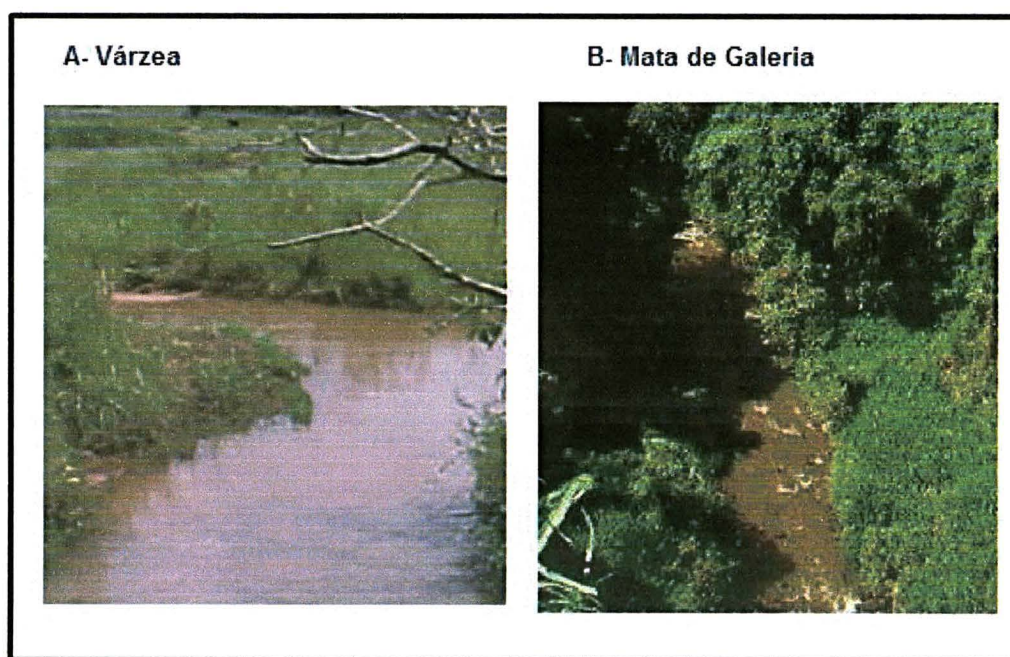
Ao longo dos rios observa-se uma sucessão secundária da floresta aluvial. De acordo com LEITE (1994) a formação aluvial ocorre geralmente com a insuficiência de drenagem de talvegues que dificultam a descarga de água. Estas planícies apresentam dois tipos fundamentais de ambientes: os menos hidromórficos, com solo mais bem estruturado e ambientes encharcados, como solo azonal, colonizados por formações pioneiras.

As florestas de galerias são formações vegetais que se desenvolvem ao longo de um curso d'água, onde se forma uma faixa de vegetação com largura que varia entre alguns até algumas centenas de metros, de acordo com o solo, relevo e microclima, que compõem o ambiente ciliar. A formação vegetal é rica em espécies arbóreas e herbáceas, e apresenta uma formação temporal e uma variação espacial paralela e perpendicular à direção do curso de água, recebendo forte influência da ação antrópica .

Segundo MUELLER (2001), o ambiente ciliar é uma proteção eficaz, tanto dos corpos d'água, quanto do solo de suas margens e dos lençóis freáticos. Também atua no amortecimento do impacto da erosão em áreas mais altas, quando nelas se desenvolve a agricultura. LEITE (1994) define ambiente ciliar como uma formação vegetal que está

associada aos cursos d'água, cuja ocorrência é favorecida pelas condições físicas locais, principalmente relacionadas à maior umidade do solo. Essas áreas são de fundamental importância no gerenciamento ambiental, pois, além de contribuírem para a manutenção da qualidade dos recursos hídricos, funcionam como corredores úmidos entre as áreas agrícolas, favorecendo a proteção da vida silvestre local. Nos vales fluviais mais encaixados, formados por vertentes íngremes, a floresta se assemelha à mata mesófila (Figura 2-B), apresentando domínio do extrato arbóreo, com dossel contínuo nas áreas melhor conservadas. De acordo com a Figura 2, nos vales mais amplos e de solos freqüentemente encharcados, encontram-se as várzeas, correspondendo à vegetação de porte herbáceo-arbustivo (Figura 2-A).

FIGURA 2- MATA DE GALERIA E VÁRZEA.




Ao longo da Bacia do Rio Paracatu, observa-se um ambiente ciliar totalmente alterado. A degradação do ambiente ciliar nesta área contribui para intensificar a erosão do solo, destruição da vida silvestre e o desfiguramento da paisagem à beira do rio. Nas baixadas são encontradas vegetações de várzea, em solo pouco estruturado. Maior parte das espécies



arbóreas que constituem este ambiente são as típicas de primeira ocupação. A região ao redor do ambiente ciliar é composta por pastagens, áreas agrícolas e plantações de cana e milho (Figura 3).

FIGURA 3- IMAGEM IKONOS SOBREPOSTA AO MODELO DIGITAL DO TERRENO



A região apresenta problemas ambientais decorrentes da ausência da vegetação ciliar em algumas áreas, o que levou à erosão acelerada das margens de córregos que fluem para Rio Paracatu, com o surgimento de voçoroca. A contaminação dos cursos d'água em função da intensa atividade agrícola também é verificada.

De acordo com levantamentos *in loco*, observam-se alguns focos de reflorestamento de eucaliptos próximos ao ambiente ciliar, com finalidade de repovoamento.

No Estado do Paraná, dos mais de 100.000 km de margens de rio, estima-se que mais de 60 % desses já não possuem matas de galeria ao longo dos rios. Desta forma, a recuperação das matas de galeria deve estar diretamente ligada ao conhecimento das espécies que as compõem (LINGNAU et al., 2002). É importante destacar que parcela significativa dos



impactos ambientais e sociais decorrentes da remoção das matas ciliares não é absorvida pelos agentes que a ocasionaram.

Constatados os danos ambientais provocados pela destruição e degradação do ambiente ciliar, foi aprovada uma legislação no sentido de fiscalização e sanção, Código Florestal nº 4.771, de 15-9-1965, que com algumas alterações ainda permanece em vigor. Considera-se de preservação permanente as florestas e demais formas de vegetação natural situadas ao longo dos rios e qualquer curso d'água, em faixa marginal de 30 metros para rios com largura de menos de 10 metros, como é o caso no Rio Paracatu. Na Figura 4 o polígono em branco mostra a pequena faixa remanescente do ambiente ciliar, onde em alguns trechos do curso do rio é quase inexistente- em torno 30% do ambiente ciliar amparado por lei já foi devastado de acordo com análise realizada sobre a imagem retificada..

FIGURA 4- REMANESCENTE DO AMBIENTE CILIAR

Banda 4- Infravermelho





O uso de espécies nativas representa uma importante forma de restabelecer as condições anteriormente dominantes, e diminuir os prejuízos decorrentes da degradação ambiental. Algumas áreas ao longo do Rio Paracatu foram recuperadas com espécies nativas, recentemente. Observa-se na Figura 4, que existem áreas de reflorestamento com Eucaliptos bem próximos ao ambiente ciliar.

Apesar dos dispositivos legais disponíveis, o processo de degradação é contínuo não só das matas ciliares, mas também de florestas de preservação permanente junto as propriedades rurais. As imagens tipo Ikonos (multiespectral) da região, permitem uma visão detalhada do ambiente ciliar, o qual viabiliza o planejamento estratégico da recomposição e monitoramento das áreas de preservação permanente. As diferentes feições foram interpretadas e verificadas *in loco* de forma a aferir a interpretação da imagem. O conhecimento acurado do mapa do uso do solo é fundamental para qualquer plano de fiscalização e recuperação do ambiente ciliar.

O avanço de técnicas de classificação contextualizada de imagens de alta resolução pode melhorar sobremaneira a qualidade de geração de dados vetoriais da cena, e pode servir de referência a aplicações em áreas congêneres.

### 2.3- DESCRIÇÃO DAS CLASSES DE USO E COBERTURA DA TERRA

Com objetivo de criar um mapa temático de vegetação nomeadamente no ambiente ciliar foram identificados *in loco*, com o auxílio de técnicos da EMATER, as seguintes classes:

a)- Ambiente Ciliar: a floresta ciliar composta pelas classes de *várzea* e *mata de galeria*. A *várzea* é composta de comunidades de vegetais das planícies aluviais que refletem a cheia do

rio. A *mata de galeria* é vegetação ao longo dos rios em áreas menos inundáveis e mais estruturadas (LEITE,1994);

b)- Floresta: remanescente da floresta nativa (Floresta Estacional Semi-decidual) situada algumas propriedades rurais fora do ambiente ciliar. As áreas remanescentes encontram-se em estágio sucessional avançado (vegetação secundária);

c)- Eucalipto: áreas de reflorestamento;

d)- Capoeirinha: vegetação alterada, áreas de sucessão com características herbáceo-arbustiva;

e)- Pasto: vegetação campestre em diferentes estágios de manejo;

f)-Solo exposto: áreas sem cobertura vegetal preparadas para plantio;

g) Agricultura: área subdividida em diferentes culturas de época tais como: *cana de açúcar* e *outras culturas* (milho e mandioca);

h) Solo urbano: sítio urbano de Nova Esperança nas proximidades da zona rural.

## 2.4- MATERIAL E DADOS DISPONÍVEIS

Sobre a região foram disponibilizados os seguintes dados:

- a) Imagem IKONOS multiespectral 4 bandas, de janeiro de 2001 (ANEXO 1);
- b) Modelo digital do terreno baseado em curvas de nível com equidistância de 20 metros. As curvas de nível foram obtidas do mapa topográfico da região na escala 1:50.000 (cessão Paraná 12 meses, Dpto de Engenharia Florestal, UFPR);
- c) Levantamento GPS para retificação e interpretação da imagem (cessão Paraná 12 meses, Dpto de Engenharia Florestal, UFPR);
- d) Verificação em campo dos diferentes usos e cobertura da terra interpretados na imagem. Reconhecimento da área de estudo por meio de registro fotográfico (Apoio EMATER, Nova Esperança);

Os softwares utilizados neste trabalho foram:

- a) ERDAS Imagine 8.4, retificação de imagem e digitalização da bacia do Rio Paracatu e estradas da região em formato Arc-Info (Laboratório de Sensoriamento Remoto e SIG do Curso de Engenharia Florestal, UFPR);
- b) ARC-VIEW 3.2 Spatial Analyst, geração do modelo digital do terreno (cessão Universidade Karlsruhe, DE, Dpto de Geomática, UFPR );
- c) E\_cognition 2.1, segmentação multi-resolução (método FNEA) e lógica fuzzy (cessão IPF- Universidade de Karlsruhe DE, Dpto. de Geomática UFPR);
- d) Idrisi 3.2, classificação por lógica fuzzy ao nível de pixel, utilização dos algoritmos maxver e crosstab de análise estatística (cessão Departamento de Geografia, UFPR);
- e) ARC-VIEW 3.2, elaboração dos mapas temáticos de vegetação (cessão Departamento de Geomática, UFPR);

### 3- REVISÃO DA LITERATURA

Neste capítulo serão abordados os conceitos e o estado da arte dos principais tópicos de relevância ao desenvolvimento da metodologia proposta no capítulo 5, principalmente no que se refere a semântica e lógica fuzzy.

#### 3.1- COGNIÇÃO E SEMÂNTICA

“Cognição” é sinônimo de conhecer. O termo é vastamente usado por psicólogos e pedagogos para atividades mentais de como utilizar a linguagem, raciocinar, resolver problemas, emitir e compreender conceitos, recordar e imaginar. A percepção humana é um processo ativo e altamente integrado que se desdobra em várias etapas desde a visualização até a interpretação baseada no conhecimento (FRANK, 1998).

MECKLENBRÄUKER et al. (1998) apresentam o termo cognição espacial como a capacidade do ser humano em armazenar informação sobre a organização do espaço. O espaço é composto por objetos que possuem muitas propriedades e relações com outros objetos. O cérebro humano pode armazenar informações sobre os objetos tanto no âmbito espacial (localização) como no âmbito não espacial (atributo). A cognição espacial é baseada no conhecimento armazenado no cérebro humano, logo depende de condicionantes *a priori*. BERENDT et al. (1998) salientam que a ciência cognitiva vem ganhando interesse em Sensoriamento Remoto no que se refere à percepção e análise de imagens. No que concerne à Inteligência Artificial, o conhecimento pode ser definido como a informação ou os modelos usados pelo computador para interpretar, prever e responder apropriadamente questões do mundo real (FISCHLER & FIRSCHEIN, 1987).

A cognição espacial tem sido amplamente utilizada nas ciências cartográficas. PETERSON (1995), citando Neisser, define cognição como todos os processos pelos quais

um estímulo sensorial (por exemplo a visão humana) é transformado, reduzido, elaborado, armazenado, recuperado e utilizado. Psicólogos ainda não conhecem completamente como é processado o conhecimento lógico pelo cérebro humano. Contudo, o entendimento de percepção visual que permite adquirir o conhecimento lógico é bastante útil quando se utilizam mapas e imagens como fonte de informação espacial.

A percepção de objetos na imagem é apoiada na base do conhecimento e seu contexto, que neste caso é compreendido como o conjunto de circunstâncias que acompanham um conhecimento. Para o filósofo Kant, citado por BÄHR (2002), a cognição manifesta-se por conceitos, ou seja, pelas habilidades intelectuais do ser humano. O processo de percepção necessita de um conhecimento pré-definido. A relação entre os objetos também depende desta capacidade humana de dar significados às coisas.

A representação do conhecimento é uma translação de uma situação ou problema em um sistema constituído de um vocabulário que nomeia os objetos e suas relações. MOLENAAR (1998) descreve os conceitos de sintaxe e semântica, na representação do conhecimento. A sintaxe se refere às regras formais que estruturam relações. A semântica por sua vez, refere-se ao significado dos objetos dentro de determinada situação. A semântica dos objetos espaciais pode ser manipulada por meio de uma sintaxe.

No âmbito da imagem, objetos são agrupados de acordo com um modelo cognitivo. Existe uma capacidade intuitiva do cérebro em agrupar coisas similares. Objetos ou segmentos de características semelhantes podem ser agrupados formando regiões ou superobjetos. Esta capacidade de agrupamento é tão mais apurada quanto maior for a base do conhecimento, quanto mais bem definido o objetivo a ser alcançado. Os objetos e (ou) regiões que representam o mundo real possuem relações que podem ser expressas por um modelo semântico, de forma a exprimir a visão humana do arcabouço espacial (VORWERG & RICKHEIT, 1998).

VORWERG & RICKHEIT (1998) salientam que a relação entre um objeto pode ser expressa através da posição de um segundo objeto. Exemplo: “O objeto A está próximo de B”, ou “B está próximo de A”. Este tipo de relação baseada no ponto de vista é denominada cognição assimétrica. De acordo com GEHRKE & HOMMEL (1998) existe uma grande evidência que relações espaciais são codificadas hierarquicamente pelo cérebro humano.

O conhecimento pode ser representado hierarquicamente por meio de uma estrutura que relaciona objetos e regiões em termos de semântica. A rede hierárquica de conhecimento permite representar o conhecimento geográfico de forma lógica. As relações entre objetos podem ser organizadas hierarquicamente próximo ao raciocínio humano (FISCHLER & FIRSCHEIN, 1987; BERENDT et al. 1998; FRANK, 1998; KNAUFF, 1998).

A representação do conhecimento em análise de imagens provenientes de Sensoriamento Remoto encontra-se em fase inicial de implementação. Uma das principais restrições reside na diferença de percepção dos objetos pelo cérebro e a interpretação dos objetos pela máquina, em geral compostos por modelos simplificados (HOFMANN & REINHARD, 2000).

### 3.2- INTERPRETAÇÃO DA IMAGEM

O reconhecimento de feições em uma imagem pelo cérebro está diretamente ligado à cognição. O conhecimento prévio armazenado permite distinguir objetos diferentes numa imagem através de um processo puramente abstrato (BERENDT 1998; BARKOWSKY, 2002). De acordo com BÄHR (2002), a interpretação da imagem pelo cérebro humano passa pelas seguintes etapas: visualização; reconhecimento e análise. A visualização refere-se ao primeiro impacto que a imagem causa ao cérebro humano, capacidade humana de associação. O reconhecimento é baseado na cognição e permite distinguir alguns grupos de feições de

maneira genérica implicando relações entre os objetos. O processo de análise vai além do reconhecimento, pois requer que o contexto seja introduzido.

Mesmo que o cérebro humano esteja familiarizado com o ambiente da imagem, a sua interpretação estará vinculada a conceitos predeterminados como parte do processo cognitivo, onde habilidade intelectual exerce um papel fundamental.

O processo cognitivo pode ser executado de forma explícita através da semântica. O conhecimento conduz a rede semântica onde objetos do mundo real são descritos como são percebidos pelo usuário (QUINT, 1997). AVERY & BERLIN (1993), comentam que a interpretação da imagem envolve uma certa quantidade de subjetividade. Em certas circunstâncias o processo mental de dedução e associação pode permitir a detecção de feições muitas vezes pouco evidentes isoladamente na imagem. A interpretação da imagem devido à abstração e subjetividade é de difícil automação.

FRANK & RAUBAL (1999) salientam que a semântica é a maneira de representar a interpretação da imagem em uma estrutura formal menos subjetiva. O reconhecimento de objetos na imagem pode ser modelado através de suas relações espaciais. No entanto, existe sempre alguma incerteza na representação simplificada do mundo real. O sucesso de interpretação da imagem e a estruturação da semântica dependem da capacidade de generalização que atenda determinado objetivo (GUNST & VOSSELMAN, 1997).

O resultado da interpretação da imagem próxima ao raciocínio humano parte de um conjunto de objetos ou feições que podem ser organizadas hierarquicamente com seus atributos concretos e suas relações baseadas no conhecimento. A significância dos objetos é estruturada logicamente, de forma a refletir de maneira eficaz o conhecimento dentro de um ambiente específico (FISCHLER & FIRSCHEIN, 1987; BERENDT et al., 1998; FRANK, 1998; KNAUFF, 1998).

A interpretação da imagem pode resultar num modelo reduzido da realidade em relação a determinado ponto de vista (objetivo). Os descritores da fotointerpretação convencional tais como: forma, textura, cor, padrão, posição e tamanho, podem ser extrapolados ao nível de domínio da imagem. A textura, por exemplo, fornece intuitivamente medidas de propriedades como rugosidade, suavidade e regularidade dos elementos da imagem. A textura transcende a interpretação visual podendo ser analisada em termos estatístico e espectral (IRON & PETERSON, 1981). Desta forma, os objetos são reconhecidos usando-se estes descritores que permitem uma análise contextualizada atingindo a significância esperada.

RICHARDS & JIA (1999) comentam que a interpretação da imagem envolve a participação humana direta e que apesar de ser bastante efetiva no que se refere à avaliação espacial, deixa a desejar na avaliação de aspectos quantitativos. Com referência à orientação a objeto, interpretar imagens é estabelecer a correspondência entre o objeto e a feição no terreno. Isto requer uma descrição estruturada, uma semântica, que relaciona objetos com seus atributos e suas ligações com outros objetos. A sintaxe pode ser manipulada automaticamente de maneira a formalizar o conhecimento sobre os objetos de forma contextualizada (JANSSEN & MOLENAAR, 1995; ALHAJJ & POLAT, 2002).

### 3.3- SEGMENTAÇÃO

Objetiva-se com a segmentação dividir uma imagem em grupos de pixels ou objetos de acordo com determinado grau de homogeneidade, a fim de associá-los a uma feição do terreno. Dependendo do tipo de imagem e do objetivo, diferentes métodos de segmentação podem ser aplicados.

A segmentação de uma imagem pode ser definida conforme FU & MUI (1981) como a divisão de uma imagem em diferentes regiões, onde cada uma destas regiões possui propriedades específicas. TILTON (2002) destaca que as regiões consistem em um



agrupamento de valores multiespectrais ou hiper-espectrais similares. A segmentação é uma componente importante para o reconhecimento de padrões. Entretanto, não existe um modelo formal para segmentação. O processo é essencialmente empírico e, em geral, ajustável aos diferentes tipos de imagem, com limiares definidos face a complexidade dos alvos investigados.

De acordo com GONZALEZ & WOODS (2000) e TILTON (2002) os algoritmos para segmentação de imagens são geralmente baseados nas propriedades básicas de valores de níveis de cinza, descontinuidade e similaridade. Na primeira categoria, a abordagem é particionar a imagem baseada em mudanças bruscas de tons de cinza. Este tipo de segmentação é utilizado quando se deseja detectar bordas e pontos isolados. A segunda categoria (similaridade) baseia-se em limiarização e crescimento de regiões.

Matematicamente, a operação de limiarização pode ser descrita como uma técnica de processamento de imagens na qual uma imagem de entrada  $f(x,y)$  de  $N$  níveis de cinza produz uma imagem de saída  $g(x,y)$ , chamada limiarizada, cuja quantidade de tons de cinza é menor que  $N$ . A técnica mais simples de limiarização é a do particionamento do histograma da imagem por um limiar único  $T$ .

Seja:

$$g(x,y) = 1 \text{ se } f(x,y) \geq T; \quad (1)$$

$$g(x,y) = 0 \text{ se } f(x,y) < T; \quad (2)$$

onde os pixels poderão ser rotulados de 1 ou 0, sendo  $T$  um valor de nível de cinza predefinido, ao qual é chamado de limiar (GONZALEZ & WOODS, 2000).

A segmentação é realizada, varrendo a imagem, pixel a pixel, e associando cada pixel a uma determinada classe ou objeto, dependendo do nível de cinza, se for maior ou menor que  $T$ . Neste caso considera-se apenas a informação espectral de cada pixel para determinar as regiões homogêneas.

### 3.3.1- Segmentação orientada a regiões

De acordo com GONZALEZ & WOODS (2000) o crescimento de regiões é uma técnica de agrupamento espacial no qual somente pixels adjacentes, contíguos na imagem, podem ser agrupados. Esta técnica consiste em partir de um ou vários pixels considerados uniformes, analisar os pixels na vizinhança e adicionar os vizinhos que forem similares ao grupo inicial, de maneira que a região formada cresça num processo iterativo que termina quando as fronteiras naturais dos objetos presentes na cena forem atingidas. Ao final do processo, a imagem encontra-se dividida em várias sub-regiões.

Seja  $I$  todos os objetos da imagem, a segmentação por região pode ser vista como o processo de subdivisão de  $I$  em  $n$  sub-regiões,  $R_1, R_2, \dots, R_N$ , tal que:

1.  $\bigcup_{i=1}^n R_i = R$ , onde todos os pixels devem pertencer à uma única região,
2.  $R_i$ , região conexa,  $i=1,2,3 \dots n$ ;
3. As regiões devem ser disjuntas, tal que,  $R_i \cap R_j = \emptyset$  para todo  $i$  e  $j$ ,  $i \neq j$ ;
4. Os pixels em  $R_i$  de uma mesma região devem possuir a mesma intensidade ou característica;
5.  $P(R_i) = \text{verdadeiro}$  para  $i = 1, 2, \dots, n$  e para diferentes regiões  $P(R_i \cup R_j) = \text{falso}$ , para  $i \neq j$ . Em que  $P(R_i)$  é um predicado lógico sobre os pontos do conjunto  $R_i$  e  $\emptyset$  é o conjunto vazio;

A condição (1) sugere que a segmentação deve ser completa. A segunda condição requer que pixels de uma mesma região devem ser conexos.

A região cresce através da agregação de pixels com características similares tipo cor, brilho. A agregação que forma o objeto ou região é interrompida até não poder crescer mais,

baseados nos parâmetros associados e limiar (GONZALEZ & WOODS, 2000; LOPES, 2002).

TILTON (2002) apresenta um método denominado híbrido que se refere ao refinamento dos processos de segmentação, alternando o método de crescimento de regiões e limiarização. O crescimento de regiões controla a geração de regiões e este cria um limiar para o agrupamento. O processo de limiarização fica restrito na junção de regiões adjacentes.

### 3.3.2.- Segmentação Multi-resolução

Uma das grandes desvantagens do agrupamento convencional é não considerar a característica espacial do *pixel*. Em imagens de alta resolução este tipo de algoritmo possui uma eficiência reduzida. Segundo SCHIEWE, TUFTE & EHLERS (2001), a alta resolução dos sensores aumenta o campo de variabilidade, e conseqüentemente o decréscimo operacional do agrupamento baseado somente na variância espectral.

Alguns métodos operacionais utilizam informação de textura para a segmentação. A segmentação em geral é baseada na imagem texturizada oriunda de matrizes de co-ocorrência, coeficientes *wavelets* ou índices fractal (BLASCHKE & HAY, 2002). Deve-se ter em conta que a característica de textura seja evidente na imagem para a eficácia da segmentação (HOFMANN et al. 1998).

A fim de superar as limitações dos segmentadores convencionais em imagens multiespectrais de alta resolução espacial, estudos se voltam a analisar os objetos de estrutura topológica vetorial agregado a informações espectrais. Desta forma, o aspecto espacial possui um importante papel e pode ser descrito por relações topológicas entre os objetos vizinhos. KOK, SCHNEIDER & ARMER (1999) salientam que o procedimento de segmentação deve ser moldado de acordo com a resolução da imagem e com a escala (tamanho) esperada para os objetos.

SOLBERG et al (1996) enfatiza que a interpretação da cena e a informação contextual são importantes. Basicamente relacionando um pixel com outras medidas, mais informação pode ser derivada. O contexto pode ser definido ao longo de duas dimensões: a) dimensão espectral; b) dimensão espacial. A dimensão espectral se refere às diferentes bandas do espectro eletromagnético. Modelando a correlação espectral, freqüentemente melhora a separação entre classes. A dimensão espacial é definida pela correlação espacial entre os pixels adjacentes e suas vizinhanças (FAN & XIA, 2001).

TON et al (1991) apresenta uma alternativa para o melhoramento da qualidade da segmentação convencional baseada no conhecimento semântico da imagem. Esta imagem é segmentada considerando o conhecimento *a priori*. O conhecimento considera relações espaciais tais como: proximidade, conectividade e a orientação relativa entre as várias feições da imagem. Este processo compreende as seguintes fases: o uso de uma imagem Kernel que incorpora a interpretação da imagem; automação da aquisição do conhecimento espectral e a segmentação hierárquica (TON et al, 1991; GORTE, 1998).

BAATZ & SCHÄPE (2001) salientam que o conhecimento semântico leva a uma melhora no agrupamento de regiões, contudo não contempla necessariamente a homogeneidade. Os mesmos autores propõem que o primeiro passo de processamento seja a criação de objetos primitivos, onde estes objetos ou regiões resultantes seriam a matéria prima para classificação e posterior refinamento.

BLASCHKE & HAY (2002) introduzem o conceito de evolução de rede fractal (*FNEA: fractal net evolution approach*). Considera-se a imagem de sensoriamento remoto como de natureza fractal. Ao se segmentar a imagem simultaneamente de forma fina e de forma grosseira, dá-se origem a escalas de segmentação. O procedimento é similar ao crescimento de regiões que agrupa pixels ou sub-regiões em regiões maiores. Segundo BLASCHKE & HAY (2002) e WILLHAUCK, BENZ & SIEGET (2002) a segmentação da imagem resulta

em segmentos ou objetos, que baseados em parâmetros espectrais e de forma, podem ainda ser reagrupados em objetos maiores denominados superobjetos ou regiões. Estas regiões possuem relações com os segmentos que as constituem num nível hierárquico mais baixo. Esta é a principal característica do procedimento de segmentação denominado por BAATZ & SCHÄPE (1999) de segmentação Multi-resolução.

Segundo IVITS & KOCH (2002) o método proposto *FNEA* utiliza técnicas de segmentação baseada na estrutura de orientação a objetos. Ao contrário dos métodos fundamentados em pixels, a segmentação da imagem extrai objetos de interesse na escala desejada, onde a escala mais fina (objetos primitivos) está próxima da resolução da imagem.

BLASCHKE et al (2000) comenta que não existe uma escala ideal para os objetos. O olho humano reconhece pequenos e grandes objetos simultaneamente, mas não consegue distinguir exatamente dimensões. A detecção de um objeto pode ser tratada de acordo com a resolução do sensor, em geral a escala de um objeto da imagem deve ser significativamente maior que a escala do ruído relativo à textura. Isto assegura que a segmentação subsequente possa ser gerada a partir de objetos significativos. Os objetos relativos aos diferentes níveis de segmentação, tanto no âmbito espacial quanto no âmbito temático, podem ser combinados de forma a compor um determinado aplicativo.

De acordo com SCHNEIDER & STEINWENDNER (1999), os objetos gerados não se restringem às propriedades espectrais. Entre outros aspectos que podem ser explorados encontram-se a textura, o tamanho e a forma dos objetos, bem como a associação espacial entre os objetos que compõem a cena. Forma e tamanho são elementos importantes para a discriminação de objetos que possuem a mesma resposta espectral. Além dos parâmetros de forma inerentes aos objetos, a análise da teoria dos fractais pode ser útil à descrição de pequenas variações de forma. Segundo PALMER (1988), a dimensão fractal pode ser utilizada como um índice da dependência espacial de uma variável do objeto.

### 3.4- ANÁLISE ORIENTADA A OBJETO

Orientação a objeto pode ser entendida, no âmbito da imagem, como a análise da relação de um objeto com os seus objetos vizinhos. KOK, SCHNEIDER, & ARMER, (1999) definem “orientação a objeto” como elemento da imagem constituído de relações espaciais. No que se refere a diferentes níveis de segmentação, as relações entre os objetos ocorrem também ao nível de objetos e subobjetos.


KUFONIYI (1995) e JANSENN & MOLENAAR (1995) salientam que a lógica de orientação a objeto preconiza as características semânticas dos objetos, que podem ser analisadas de acordo com seus aspectos geométricos e temáticos, respectivamente. O primeiro compreende topologia, forma e posição, o segundo atributos não espaciais dos objetos.

A topologia é utilizada quando se deseja implementar relações entre os polígonos gerados a partir do agrupamento de pixels. Seu objetivo é descrever as propriedades espaciais de áreas de tal maneira que os atributos não-espaciais associados aos elementos ou entidades poligonais possam ser manipulados. Neste caso, faz-se necessário armazenar informação referente à vizinhança dos objetos (BURROUGH & McDONNELL, 1998). Os relacionamentos espaciais entre os objetos podem ser explicitados pelas seguintes relações topológicas: *conectividade*, *adjacência*, *disjunção* e *contingência* (Figura 5).

- Conectividade: de acordo com MOLENAAR (1998), objetos estruturados topologicamente, significa que quaisquer dois objetos  $O_i$  em  $O_j$  estão conectados se  $O_i \cap O_j \neq \emptyset$ .
- Adjacência : Dois objetos  $f_1$  e  $f_2$  são adjacentes se estes compartilham um limite  $e_i$ ,
- Disjunção : é definida quando não existe limite comum entre os objetos  $O_i \cap O_j = \emptyset$  ;

- **Contingência:** compreende as relações existentes entre objetos contidos em outros objetos.

FIGURA 5- RELAÇÕES TOPOLÓGICAS DE POLÍGONOS.



Conseqüentemente, o conceito de vizinhança entre objetos ou regiões é definido por meio das relações topológicas (BURROUGH & McDONNELL 1998; MOLENAAR, 1998; MOLENAAR & CHENG, 2000). Estando definidos os relacionamentos topológicos sobre os objetos, pode-se a partir das propriedades de atributos (ex.: textura, forma, brilho, etc.) e propriedades geométricas (ex.: área e perímetro) realizar operações entre objetos. Estas operações produzem como resultado um agrupamento de objetos e valores que satisfazem a determinada restrição espacial (CAMARA & MEDEIROS, 1998; MOLENAAR, 1998).

No processo de classificação, o contexto entre os objetos está vinculado à análise de relacionamentos- uma classe A só existe se for adjacente a uma classe C, ou , A só existe se estiver contida em C. Tanto as regras Booleanas, como funções de pertinência, são oriundas das propriedades que compõem os objetos, propriedades estas de carácter geométrico e descritivo. Segundo MOLENAAR & CHENG (2000), o agrupamento de objetos com topologia vetorial permite a determinação de regiões, baseadas em características semânticas. De acordo com BURROUGH & McDONNELL (1998), um mapa temático pode ser composto por conjuntos de regiões que compartilham de uma mesma classe. Contudo, uma região pode ser delimitada praticamente sob qualquer ângulo, sob diferentes óticas, permitindo assim flexibilizar limites. Uma região se distingue das demais por possuir

características próprias. Cabe aduzir o termo *domínio* para justificar as características inerentes aos fenômenos naturais localizados junto as unidades físicas estruturais, climáticas, morfológicas e espectrais, como por exemplo: domínio de várzea, domínio de erosão, domínio espectral, etc.

GORTE (1998) & BLASCHKE et al.(2000) comentam que a orientação a objeto permite ao usuário definir regras complexas baseadas em características espectrais e de relações espaciais. Este modelo permite que a semântica possa ser desenvolvida apoiada em parâmetros físicos e de conhecimento sobre relacionamentos.

### 3.5- LÓGICA FUZZY

A melhora na resolução espacial de uma imagem demanda uma análise que considere o conhecimento do intérprete humano de forma a refletir melhor a subjetividade na informação. Desta forma, a lógica fuzzy parece ser mais adequada quando se pretende representar o conhecimento no processo de classificação digital.

O conceito de conjuntos difusos, nebulosos ou fuzzy, proposto por ZADEH (1965), é uma generalização do conceito da teoria clássica dos conjuntos. De acordo com BURROUGH & McDONELL (1998) o conjunto fuzzy refere-se a conceitos inexatos para uma metodologia de caracterização de classes, que por várias razões não se tem ou não se pode definir limites rígidos (bordas) entre classes. A utilização de um conjunto fuzzy é em geral aplicada sempre que se tiver que lidar com ambigüidade, abstração e ambivalência em modelos matemáticos.

Seja  $X$  um espaço de objetos (pixels ou segmentos) e  $x$  um elemento qualquer de  $X$ . Um conjunto clássico  $A$ ,  $A \subseteq X$ , é definido como uma coleção de elementos ou objetos  $x \in X$ . Nesta relação, cada  $x$  pode pertencer ou não ao conjunto.



É possível definir uma função que caracterize o grau de pertinência de cada elemento  $x$  em  $X$ . Pode-se representar o conjunto  $A$  por um conjunto de pares ordenados  $(x, 0)$  ou  $(x, 1)$ , os quais indicam se  $x \in A$  ou  $x \notin A$ , denominado Booleano.

O conjunto fuzzy expressa o grau para o qual um elemento pertence a um conjunto utilizando uma função de pertinência. Então, esta função característica de um conjunto fuzzy apresenta valores variáveis entre 0 e 1, os quais denotam o grau de pertinência de um elemento em um dado conjunto (ZADEH, 1965; LEE & ZHU, 1995; METTERNICHT, 1999; VICENTE et al. 1999; AZEVEDO et. al 2000).

Se  $X$  é uma coleção de objetos de  $x$  elementos, então um conjunto fuzzy  $A$  em  $X$ , é um conjunto de pares ordenados, tal que:

$$X = \{x\} \quad (1)$$

$$A = \{x, f_A(x)\}; x \in X \quad (2)$$

Onde

$A$  = Conjunto Fuzzy;

$X$  = Espaço dos Objetos;

$f_A(x)$  = Função de Pertinência.

Nas expressões (1) e (2) o conjunto fuzzy  $A$  em  $X$  é caracterizado por uma função de pertinência  $f_A(x)$  que associa cada ponto em  $X$  a um número real no intervalo  $[0, 1]$ . O valor de  $f_A(x)$  representa o grau de pertinência de  $x$  em  $A$ . Desta forma, pontos podem pertencer a um conjunto fuzzy num grau maior ou menor (WANG, 1990a; AZEVEDO et al, 2000).

Um conjunto fuzzy é unicamente especificado por sua função de pertinência. Expressa por  $f_A(x)$ , definido o grau de pertinência de  $x$  em  $A$  (Figura 6).

A cardinalidade do conjunto fuzzy para o espaço dos objetos  $X$  discreto é expressa por:

$$|A| = \sum_{x \in X} f_A(x),$$

$$\text{e no caso de } X \text{ contínuo por: } |A| = \int_X f_A(x) \quad (3).$$

O core do conjunto A é dado pelo conjunto de pontos  $x$  em  $X$  tal que  $f_A(x)=1$  ou

$$\text{Core}(A) = \{x | f_A(x) = 1\} \quad (4)$$

Os pontos de cruzamento ou *crossover* é dado por  $f_A(x)=0,5$  ou


$$\text{Cross}(A) = \{x | f_A(x) = 0,5\} \quad (5)$$

Amplitude ou suporte da função de pontos  $x$  em  $X$  é dado por  $f_A(x)>0$ ,

$$\text{Suporte}(A) = \{x | f_A(x) > 0\} \quad (6)$$

A função de pertinência  $f_A(x)$  pode ser delineada de acordo com os parâmetros de cardinalidade, *crossover* e suporte -expressões (3),(5) e (6). No caso de processamento digital de imagens, a aplicação da representação fuzzy se refere a classes que podem ser definidas como conjunto fuzzy e os pixels como elementos. Um pixel pode pertencer a uma determinada classe com um grau de pertinência, e a uma outra classe com outro grau de pertinência.

FIGURA 6- FUNÇÃO DE PERTINÊNCIA DE UM CONJUNTO FUZZY



Seja  $z$  o valor do atributo ex.: várzea (classe) de acordo com o gráfico da Figura 7 tem-se:


$fa(z) = 1$  se  $a \leq z \leq b$ ;

$fa(z) = 0$  se  $z < a$  ou  $z > b$ .

Os valores  $a$  e  $b$  definem os limites do conjunto  $A$ . Dependendo do valor do nível de cinza do eixo  $x$  da função, tem-se para  $z$  um valor variável em 0 e 1, no eixo  $y$ .

Em geral é comum que o core da função seja ampliado de um valor para um intervalo  $(d_1; d_2)$  como o observado na Figura 7. Assim, a zona de pertinência é ampliada. Observa-se a sobreposição da função de pertinência e pertinência abrupta (Booleana). A Figura 7 mostra as discrepâncias entre as duas funções, onde uma observação dentro da zona Booleana (em cinza) pode não estar dentro do core da função fuzzy, em amarelo. Percebe-se que os limites da função Booleana possuem um grau de pertinência  $fa(z) = 0,5$ , logo uma observação dentro da função abrupta seria associada a uma classe, enquanto na função de pertinência  $fa(z)$  existirá apenas um grau de possibilidade (0,5) de pertencer à classe várzea (ZADEH, 1965; LEE & ZHU, 1995; METTERNICHT, 1999; VICENTE et al. 1999; AZEVEDO et. al 2000).

FIGURA 7- FUNÇÃO DE PERTINÊNCIA FUZZY E PERTINÊNCIA ABRUPTA



FONTE:: adaptado de BURROUGH & MCDONNELL,1998

Um importante passo na análise fuzzy é a determinação da função de pertinência. BURROUGH & McDONNELL (1998) denominam de importação semântica a determinação

de funções de pertinência baseadas no bom conhecimento do usuário em relação ao comportamento do dado. A função de pertinência deve assegurar o grau de pertinência 1, no centro do conjunto e este valor decresce até zero para o limite externo do conjunto. Há vários tipos de distribuição de probabilidade (ex.: normal, lognormal, retangular, hiperbólica, Poisson, etc.), logo é possível obter diferentes tipos de funções de pertinência.

Uma das funções de pertinência mais comuns é a função Sigmoidal (Figura 8), dada pela expressão:

$$f_A(z) = 1 / (1 + a(z - c)^2) \text{ para } 0 \leq z \leq P, \quad (7);$$


Onde:

A o conjunto fuzzy;

a o parâmetro determinante da forma da função,

c define o valor da propriedade z (inflexão).

FIGURA 8- FUNÇÃO DE PERTINÊNCIA SIGMOIDAL



FONTE: Adaptado de BURROUGH & MCDONNELL, 1998

BURROUGH & MCDONNELL (1998) e METTERNICHT (1999) salientam que a determinação dos parâmetros da função de pertinência depende do conhecimento geográfico em questão. As funções de pertinência são utilizadas para representar o quão difuso são os limites geográficos. O tamanho da zona de transição ( $d_1; d_2$ ) e as formas da função podem ser definidas através de um conhecimento do espaço espectral fuzzy.

Tal como na teoria dos conjuntos Booleanos, os conjuntos fuzzy podem ser combinados. Seja um conjunto fuzzy **B** contido num conjunto **A**, a função de pertinência de **B** será sempre menor que a função de pertinência em **A**, para qualquer elemento  $x$  no universo **X**. A função de pertinência de um conjunto **C** resultante da união de dois conjuntos **A** e **B**, é dada pelo o maior valor de pertinência , aos conjuntos **A** e **B** de cada elemento  $x$ :

$$C = A \cup B$$

$$f_c(x) = f_a(x) \cup f_b(x) = \text{Max}\{ f_a(x), f_b(x) \}; x \in X \quad (8)$$

A função de pertinência **C** resultante da intersecção dos conjuntos **A** e **B**, é dada pelo menor valor de pertinência aos dois conjuntos:

$$C = A \cap B$$

$$f_c(x) = f_a(x) \cap f_b(x) = \text{Min}\{ f_a(x), f_b(x) \}; x \in X \quad (9)$$

Com vistas à classificação, os principais operadores quando se manipula um ou mais conjuntos fuzzy são a de união (maximização), intersecção (minimização) e negação-complemento  $f_c(x) = 1 - f_c(x)$  (BURROUGH & McDONNELL, 1998; AZEVEDO et al. 2001).

BENZ (1999) e BAATZ & SCHÄPE (2001) salientam a importância da teoria fuzzy a análise da classificação de feições espectralmente próximas entre si. O resultado da análise fuzzy é uma relevante fonte de informação que pode, junto com outras fontes de dados, permitir uma melhora significativa no processo de classificação digital. A tendência atual é que a classificação de imagens de alta resolução seja cada vez mais amparada nesta lógica.

Segundo BINAGHI et al. (1997) a estrutura fuzzy é o principal meio de integrar o conhecimento na classificação de objetos principalmente quando diferentes fontes de informação são associadas.

### 3.6- CLASSIFICAÇÃO

Segundo BLASCHKE et al. (2000) classificadores convencionais em processamento digital de imagem como mínima distância, máxima verossimilhança, dentre outros associam aos pixels um grau de associação Booleano (0 ou 1) a determinada classe, o que restringe a sua aplicação em imagens de alta resolução. Muitos autores denominam este tipo de classificadores como rígidos (*hard*). Em contraste, classificadores ditos leves (*soft*) como sistemas fuzzy e classificador Bayes que usam grau de pertinência e probabilidade *a priori*, respectivamente. O classificador Fuzzy apresenta valores intermediários que permite flexibilidade à classificação. A tendência atual é a utilização de classificadores leves, pois a principal vantagem reside na possibilidade de expressar incertezas. Com respeito ao entendimento da imagem os classificadores leves estão mais em sintonia com o processo cognitivo.

Segundo BLASCHKE et al. (2000) e BÁRDOSSY & SAMANIEGO (2002) se numa análise ao nível de pixel em imagens de média resolução, a principal fonte de informação são os valores de níveis de cinza inerentes nos pixels, numa imagem de alta resolução, a informação espectral é limitada, abrindo caminho para outros aspectos, como a forma e textura que fornecem indícios a respeito da natureza dos objetos.

BÁRDOSSY & SAMANIEGO (2002) comentam que todos os classificadores fuzzy descritos na literatura compartilham os conceitos da teoria de conjunto fuzzy, entretanto, existe uma diferença de como o dado é tratado, tanto nos estágios de treinamento como na validação. Os principais métodos são: agrupamento fuzzy, *c-means* e funções fuzzy baseada na máxima verossimilhança.

Uma outra metodologia de classificação é por meio de Redes Neurais, apoiadas em inteligência artificial. Pode ser definida como unidades (neurônios interconectados) que

trabalham em paralelo, para classificar e generalizar dados de entrada em classes de saída. São atribuídos pesos aos dados de entrada que determinam o nível de ativação da unidade na rede. A magnitude da rede é determinada por um processo de treinamento repetitivo, o qual tenta através de repetição “aprender” a saída correta para cada amostra treinada. O processo envolve a modificação dos pesos entre as unidades até que a rede esteja apta para operar resultados desejados (ZHOU & CIVO, 1996). BLASCHEKE et al.(2000) salientam que um resultado significativo requer um ótimo conjunto de treinamento e que o processo de classificação necessita de um ajustamento de vários parâmetros, o que pode restringir sua aplicabilidade.

De acordo com a pesquisa realizada por LIU et al (2001), diferentes algoritmos de classificação produzem diferentes resultados mesmo usando as mesmas áreas de treinamento. Em alguns casos, classificadores por redes neurais apresentam melhores resultados que métodos estatísticos, em outros casos a teoria da evidência de Dempster-Shafer pode ser mais apropriada. LIU et al (2002), propõem a integração de classificadores para a melhora da acurácia temática. Não obstante, foi observado por esses autores à medida que o conhecimento extra-espectral é utilizado, melhor é o resultado da classificação, o que conduz a uma tendência de inserção de um elemento espacial que agregue informações baseadas em contexto. A categorização passa do nível de pixel ao nível objeto (CLÉMENT al, 1993).

Segundo BLASCHKE et al (2000), dentre os diferentes algoritmos atualmente utilizados em Sensoriamento Remoto, aqueles que permitem a inserção do contexto são os mais promissores em termos de confiabilidade.

### **3.6.1- Inserção do contexto**

RICHARDS & JIA (1999) definem contexto como a relação de determinado pixel com os pixels da sua vizinhança. Neste trabalho, o conceito de contexto considera também a relação entre uma região com outra região (ou regiões). Métodos de classificação que consideram a categorização de determinado pixel ou objeto, baseado nas características dos pixels ou objetos vizinhos são denominados de classificador contextual. O grau com que pixels ou objetos adjacentes são correlacionados pode depender da resolução espacial e radiométrica da imagem da imagem. O contexto é um elemento muito importante no processo de classificação de imagem de alta resolução, pois este exprime uma maior possibilidade de similaridade espacial e espectral entre os objetos.

A segmentação multi-resolução é baseada em contexto e segundo BISHR (1997) e MOLENNAR (1998) permite a construção de estrutura hierárquica. BISHR (1997) salienta que o contexto é expresso através de definições semânticas dos objetos e suas estruturas descritivas. Isto significa que um objeto relativo à determinada classe se relaciona com outros objetos de acordo com um grau de hierarquia. A classificação baseada nesta estrutura de classes e superclasses através de uma relação de dependência hierárquica está subordinada ao conhecimento (GUNST & VOSSELMAN, 1997).

### **3.6.2- Regras fuzzy**

BINAGHI et al. (1997) salienta que o processo de classificação é um sistema aberto onde fontes auxiliares de dados podem ser úteis no processo de compreensão de relações entre objetos. A integração de informações (relações espaciais entre os objetos) e os dados



auxiliares (ex.: modelo de elevação, mapas topográficos, imagens com padrão de textura, etc.) são realizadas por meio de lógica fuzzy.

Os objetos da imagem segmentada tornam-se os elementos da imagem a serem categorizados. A análise da imagem é principalmente baseada em objetos e suas propriedades. As relações entre os objetos são representadas por regras fuzzy que são capazes de descrever dependências entre diferentes tipos de informação (BENZ et al, 2001; BAATZ & SCHÄPE 2001). Como consequência, dados complementares de diferentes fontes podem ser considerados na descrição das relações entre os objetos.

As principais propriedades dos objetos tais como: característica espectral, textura, forma, hierarquia e atributos podem permitir a construções de funções de pertinência que relacionem os objetos a determinada categoria (BÁRDOSY & SAMANIEGO, 2002; BENZ et al 2001; BENZ ,1999; BLASCHKE et al, 2000). De acordo com BENZ (1999), as funções de pertinência permitem a formulação do conhecimento. Os objetos que não foram associados a nenhuma classe podem ser reavaliados, o que pode melhorar sobremaneira o resultado do processo de classificação.

HOFMANN & REINHARDT (2000), salientam que o contexto dos objetos ou regiões está estritamente relacionado com as funções de pertinência, formadas a partir das propriedades dos objetos (ANEXO 3). Classes mais específicas ou subclasses derivadas de classes mais genéricas podem ser criadas. As subclasses herdam propriedades das classes superiores. A criação de subclasses a partir de classes superiores cria uma estrutura hierárquica, que se denomina especialização (KUNZ, 1999).

A formulação de regras fuzzy apoiadas nos diferentes descritores dos objetos permite a realização da semântica dos objetos ou regiões, conseqüentemente, possibilita uma classificação interativa e próxima à realidade (QUINT, 1997).

A estrutura hierárquica passa a ser uma prerrogativa do modelo orientado a objeto. Relações espaciais entre as feições podem ser explicitadas numa rede hierárquica de classes, o que permite a geração de uma estrutura lógica de dados (KOK, SCHNEIDER & ARMER, 1999; HOFMANN & REINHARDT, 2000).

### 3.7- REDE SEMÂNTICA

A rede semântica é uma notação gráfica representando o conhecimento através da conexão entre arcos e nós. A implementação computacional da rede semântica foi pela primeira vez desenvolvida através de programas de inteligência artificial. Antigamente, estruturas semânticas eram aplicadas amplamente na filosofia, psicologia e lingüística como forma de representar o processo cognitivo (SOWA, 2000).

O que é comum em todas as redes semânticas é a representação gráfica que tanto pode ser utilizada para representar o conhecimento como para apoiar sistemas de inteligência artificial (SOWA, 2000; BÜCKNER, KOCH & PAKZAD, 1999).

Algumas redes semânticas, segundo SOWA (2000), foram explicitamente desenhadas para implementar hipóteses sobre os mecanismos do processo cognitivo. Muitas vezes o raciocínio computacional pode conduzir as mesmas conclusões que o raciocínio humano, desde que uma rede de assertivas possa ser eficientemente estruturada.

O tipo mais antigo de rede semântica é a denominada “definidora” que enfatiza subtipos (relações de pertinência e subdivisões de conceitos tipo: *parte\_de*). A primeira rede semântica definidora foi descrita pelo filósofo grego Porphyri, século III a.c, baseado no método de Aristóteles para separar categorias (*genus*). A relação entre conceitos é baseada em especialização, onde, conceito mais geral é denominado *supertype* ou *hypernym* e conceito mais especializado é denominado *subtype* or *hyponym*.

Tendo como referencia a orientação a objeto, KOCH, PAKZAD & TÖNJES (1997) salientam que a especialização de um objeto é descrita como relação *tipo de* e que introduz o conceito de herança hierárquica. Objetos podem também ser composto de *parte de* outros objetos maiores gerando dependências de contexto (ver item 4.2.3).

Relações geométricas entre objetos podem ser expressas através de relações de atributos. Ligações permitem restringir valores de atributos a um determinado objeto. Enquanto relações como *parte de* e *tipo de* propagam informações verticalmente (*bottom up*, *bottom down*), as relações entre atributos propagam informações horizontalmente.

## 4- METODOLOGIA

Neste capítulo será apresentado o procedimento metodológico com vistas à inserção do conhecimento baseada em segmentação hierárquica e introdução de contexto, conseqüentemente levando à categorização dos objetos por meio de lógica fuzzy.

### 4.1- SEGMENTAÇÃO DA IMAGEM

A introdução do conhecimento só pode ser efetivada após a segmentação da imagem e a geração de objetos relacionados, de acordo com o que foi comentado no item 3.3. Será apresentada a formulação da segmentação multi-resolução baseada em características espectral e espacial.

A segmentação numa primeira instância é determinada por um grau de homogeneidade que permita um agrupamento de pixels de acordo com uma resolução o mais fina possível. Usando segmentações repetidas ou re-segmentação, mais parâmetros poderão ser inseridos construindo, assim, relações entre os objetos em diferentes níveis (WILLHAUCK, 2000).

O agrupamento de objetos segue uma decisão heurística. Começando por um objeto **A** qualquer, e um outro objeto **B**, vizinho a **A**, os objetos **A** e **B** serão agrupados de acordo com um determinado critério de tolerância, baseado na homogeneidade. Se **A** e **B** se ajustam, busca-se um agrupamento com um terceiro objeto **C**. Logo, se **C** vizinho de **B**, pode ser agrupado a **B**, então, **A** deve-se juntar a **C**, (**C=A**). Caso isto não se verifique, repete-se o procedimento tomando **B** por **A** e **C** por **B**. Este tipo de heurística permite determinar o melhor ajuste entre objetos na vizinhança de **A** seguindo o gradiente de homogeneidade (MOLENAAR, 1998; BAATZ & SCHÄPE, 1999).

O critério de semelhança é usado para definir a uniformidade dos segmentos. Dois critérios são usados para descrever a separação do objeto da imagem: critério da cor (espectral) e o critério da forma (suavização e compactação). Estes critérios controlam a homogeneidade dos segmentos e regiões (BLASCHKE et al., 2000).

A descrição de heterogeneidade espectral é composta pela soma dos desvios padrão dos tons de cinza para uma dada banda  $\sigma_c$  ponderados pelos pesos  $\omega_c$ , sendo:

$$H_e = \sum \omega_c \sigma_c \quad (1)$$

Contudo, em muitos casos, a minimização exclusiva da heterogeneidade espectral resulta em segmentos fragmentados, principalmente em imagem muito texturizada. Por esta razão, em muitos casos deve-se considerar além da heterogeneidade espectral o critério de heterogeneidade espacial e, conseqüentemente, as formas dos objetos podem ser suavizadas (GORTE, 1998; KOK, SCHNEIDER, & ARMER, 1999).

BAATZ & SCHÄPE (1999) introduzem o conceito de heterogeneidade da forma ou espacial  $h_f$  é dada por:

$$h_f = l / \sqrt{n} \quad (2)$$

onde:

$l$  = perímetro que compõe do objeto

$n$  = número de pixels que compõe o objeto

A equação (2) considera a heterogeneidade como um desvio de uma forma compacta, descrita pela razão do comprimento limítrofe (*borderlength*) do objeto e o número de pixels que o compõe. Outra possibilidade de descrever heterogeneidade de forma é utilizar, ao invés de número de pixels, o comprimento de um quadrado ou retângulo que compreenda o objeto, equação 3.

$$h_f = l / b_A \quad (3)$$

onde:

$l$  = comprimento do objeto;

$b_A$  = perímetro do quadrado que compreende o objeto

BENZ , BAATZ & SCHREIER (2001) comentam que a homogeneidade espacial pode ser descrita pela compacidade (equação 2) e suavidade (equação 3).

Segundo BAATZ & SCHÄPE (1999) e BLASCHKE et al (2000), a segmentação baseada em regiões ou orientada a objeto deve considerar além dos critérios de semelhança, o parâmetro de escala- que determina o tamanho médio dos objetos.

A cor está diretamente relacionada com a homogeneidade espectral e a forma com homogeneidade espacial (HOFMANN, 2002b). A escala e os critérios de semelhança controlam o resultado da segmentação criando objetos maiores ou menores, homogêneos ou menos homogêneos, ou ainda, suavizados ou não (BAATZ & SCHÄPE, 2001; MEINEL, NEUBERT, REDER, 2002). BENZ , BAATZ & SCHREIER (2001) salientam que a escolha do parâmetro de escala e critérios de semelhança está relacionada a resoluções espacial e espectral da imagem. Neste trabalho, o critério de semelhança adotado deu um peso maior à cor, por se tratar de imagem multiespectral.

KOK, SCHNEIDER e ARMER (1999) e BAATZ & SHÄPE (1999) apresentam o princípio geral da multi-resolução ou multi-escalas. Segundo estes autores, a segmentação pode ser descrita como uma fusão de regiões. O processo inicia-se com um pixel formando um objeto ou região, sendo que, a cada etapa, um par de objetos funde-se para formar um objeto maior. O processo de fusão está baseado no critério de homogeneidade (acima referido), observando-se a heterogeneidade  $h$  entre os objetos adjacentes.

É definido um parâmetro de heterogeneidade entre dois objetos adjacentes, dados pela seguinte expressão HOFMANN (2002a):

$$h = \sqrt{\sum_d (f_{1d} - f_{2d})^2}, \quad (4)$$

onde:

$h$  heterogeneidade entre objetos para um espaço  $d$ -dimensional;  
 $f_{1d}$  e  $f_{2d}$  variância espectral de dois objetos.

A fusão local de objetos é um procedimento heurístico iterativo que objetiva alcançar uma heterogeneidade mínima no processo de agregação. A base é o grau de diferença de heterogeneidade entre duas regiões. Uma vez que a diferença decresce, torna-se maior o critério de fusão. Esta diferença otimiza o processo heurístico comparando os atributos das duas regiões. Num dado espaço de atributos (*feature space*) objetos são considerados similares se estiverem espectralmente próximos.

O critério de fusão entre duas regiões adjacentes é descrito pela mudança de heterogeneidade  $h_{dif}$  após uma fusão virtual. Dado um determinado critério de heterogeneidade para uma região, o crescimento de heterogeneidade na fusão deve ser minimizado. Existem diferentes possibilidades de descrever a mudança de heterogeneidade antes e depois da fusão. A expressão (4) corresponde à diferença de heterogeneidade considerando o tamanho dos objetos:

$$h_{dif} = h_m - (h_1 \cdot n_1 + h_2 \cdot n_2) / n_2 + n_1 \quad (5)$$

onde:

$h_1$  e  $h_2$  heterogeneidade para dois objetos;  
 $h_m$  heterogeneidade após a fusão virtual;  
 $n$  tamanho dos objetos

Pode-se atribuir um peso  $w$  considerando o tamanho do objeto, de forma que, para um número  $c$  de bandas, tem-se a seguinte expressão generalizada:

$$h_{dif} = \sum_c w_c \cdot (n_1 \cdot (h_{mc} - h_{ic}) + n_2 \cdot (h_{mc} - h_{2c})) \quad (6)$$

a heterogeneidade espectral está relacionada à variância das médias espectrais ou ao desvio padrão.

Como já foi citado, o critério de fusão depende da característica espectral (cor) e da espacial. O valor geral do critério de fusão  $f$  é determinado na equação (6), tendo em vista a forma e cor (BAATZ & SCHÄPE, 2001):

$$f = w \cdot h_{cor} + (1 - w) \cdot h_{forma} \quad (7)$$

onde:

$f$  = critério de fusão;  
 $w$  = é o peso dado a variável;  
 $h_{cor}$  = heterogeneidade espectral;  
 $h_{for}$  = heterogeneidade espacial.

As equações (7) e (8) determinam  $h_{cor}$  e  $h_{forma}$

$$h_{cor} = \sum_c w_c \cdot (n_a \cdot \sigma_c - (n_1 \cdot \sigma_1 - n_2 \cdot \sigma_2)) \quad (8)$$

onde:

$c$  = bandas;  
 $n$  = tamanho do objeto agrupado;  
 $n_1$  e  $n_2$  = tamanho dos objetos;  
 $\sigma_1$  e  $\sigma_2$  = desvios padrões dos objetos.

$$h_{forma} = w_{cp} \cdot h_{cp} + (1 - w_{cp}) \cdot h_{sv} \quad (9)$$

onde:

$w_{cp}$  = peso;  
 $h_{cp}$  = compacidade;  
 $h_{sv}$  = suavidade, a determinação de  $h_{cp}$  e  $h_{sv}$ , são descritas pelas equações (10) e (11) abaixo.



$$h_{sv} = n_a \cdot (l_a / b_a) - (n_1 \cdot (l_1 / b_1) + n_2 \cdot (l_2 / b_2)) \quad (10)$$

$$h_{cp} = n_a \cdot (l_a / \sqrt{n_a}) - (n_1 \cdot (l_1 / \sqrt{n_1}) + n_2 \cdot (l_2 / \sqrt{n_2})) \quad (11)$$

$l_1$  e  $l_2$  são os perímetros dos objetos;  
 $b_1$  e  $b_2$  são os perímetros dos quadrados envolventes;  
 $b_a$ ,  $l_a$  referem-se ao objeto fundido (virtual).

Os pesos são determinados de acordo com os critérios de semelhança definidos pelo usuário. Como mencionado anteriormente, o peso maior é dado para a variável cor, por ser a imagem multiespectral. Toda a imagem é segmentada e os objetos são gerados baseados em critérios ajustáveis de homogeneidade ou heterogeneidade espacial e espectral.

O resultado de um processo de segmentação leva a objetos primitivos como uma primeira aproximação a objetos da imagem do mundo real. A segmentação multi-resolução é, em sua essência, a técnica que começa com os objetos de um pixel. Em etapas subsequentes, numerosos objetos menores da imagem são fundidos em objetos maiores, como se procura verificar neste trabalho.


Em cada etapa, objetos adjacentes na imagem são fundidos conforme critérios de semelhança. O parâmetro escala influencia diretamente no tamanho médio do objeto: um valor de escala maior conduz a objetos maiores (Figura 9).

Os objetos gerados na imagem segmentada (Figura 9) estão inter-relacionados, de modo que cada objeto da imagem possui um contexto (vizinhança). Assim, é possível definir dependências entre os objetos. A estrutura hierárquica é dotada de relações topológicas definidas, isto é, o limite de um superobjeto é coincidente com os limites dos objetos secundários, de acordo com a Figura 9. A área representada por um objeto específico da imagem é definida pelo somatório das áreas dos subobjetos que o compõem. Cada nível é construído baseado em seus objetos secundários diretos, isto é, os objetos secundários são

fundidos em objetos maiores da imagem em um nível subseqüente, sendo que a fusão é limitada pelos limites do superobjeto.

Cada nível é construído baseado em seus objetos secundários diretos, isto é, os objetos secundários são fundidos em objetos maiores da imagem em um nível subseqüente, sendo que, a fusão é limitada pelos limites do superobjeto.

FIGURA 9- SEGMENTAÇÃO HIERÁRQUICA (MULTI-RESOLUÇÃO)



#### 4.2- DESCRIÇÃO DO CONHECIMENTO

O conhecimento pode ser entendido como as relações entre os objetos e suas feições na cena e no terreno. O conhecimento está calcado no contexto temático, ou seja, na conjuntura.

O contexto temático, aqui explicitado, é o ambiente ciliar. Num primeiro nível, deixa-se claro de que forma diferentes feições do terreno se relacionam com o ambiente ciliar. Este é um processo baseado em variáveis abstratas que diz respeito ao processo cognitivo (Tabela 2, capítulo 5).

A análise da cena depende do conhecimento *a priori*. Neste caso, a imagem e os dados complementares a ela associados, se referem ao contexto de ambiente ciliar, de forma que todo o conhecimento é dependente do que se entende por ambiente ciliar (vide capítulo 2). Desta forma, o conhecimento é expandido ao âmbito do uso do solo, ou seja, feições que se relacionem com o ambiente ciliar. Tendo em vista o grau de abstração, diferentes estruturas semânticas podem ser obtidas, o que é denominada pelos cartógrafos de generalização conceitual. O escopo do mapeamento é que define as feições de relevância bem como sua semântica. A representação do conhecimento é baseada na semântica da cena.

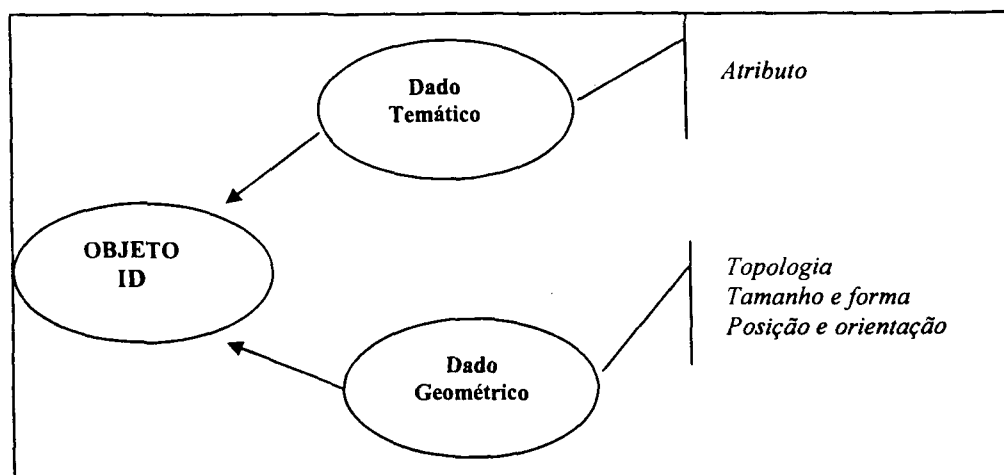
O conhecimento está apoiado no espaço (localização), tema (atributos/classificação) e no tempo. Primeiramente, a concepção de espaço é usada para organizar e estruturar a percepção humana. A formalização desta concepção espacial conduz ao modelo espacial, que de forma geral refere-se à combinação espacial e temática dos objetos. Observe-se que todo conhecimento depende da variável tempo.

A percepção humana é alicerçada no conhecimento prévio do espaço e na introspecção do observador. A representação do conhecimento pode ser vista em diferentes escalas de relacionamento. A visão do observador num primeiro momento do espaço é genérica, mas à medida que se observam mais detalhes, a complexidade cognitiva se amplia. Na generalização conceitual, o grau de relacionamento entre as feições depende da escala da observação, uma consequência direta do grau de detalhe do dado disponível (imagem) e do poder de interpretação e discriminação do observador.

#### 4.2.1- Modelo Conceitual

Neste estudo uma feição do terreno e identificada na imagem pode ser considerada como objeto no domínio da imagem. Os objetos podem ser simples ou complexos. Objetos mais complexos podem ser formados a partir da combinação de vários objetos. Uma região pode ser considerada como um objeto complexo. Neste estudo se consideram objetos (subobjeto e superobjetos) como se fossem regiões, tendo em vista que são constituídos por agrupamento de pixels. Cada objeto tem uma identidade única, contudo suas propriedades são função do tempo. Na Figura 10 assume-se que as feições do terreno ou objetos podem ser definidas por sua posição , forma e características não geométricas.

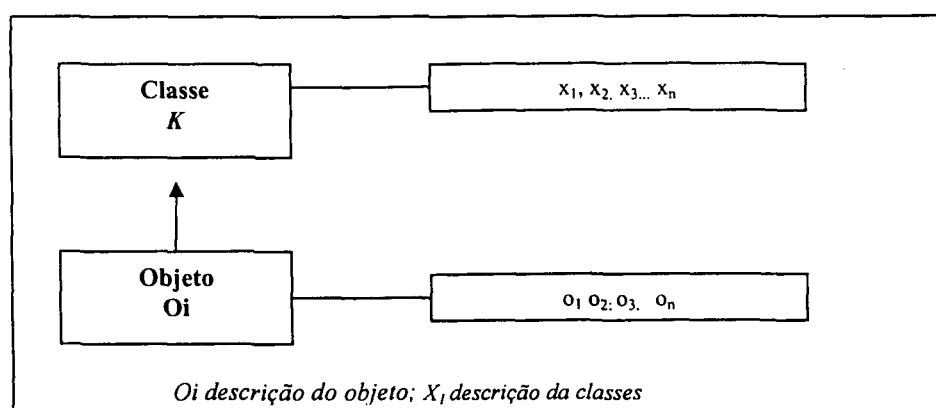
FIGURA 10- ESTRUTURA DO DADO ESPACIAL



Objetiva-se associar determinado objeto a determinado atributo temático. As classes são especificadas por objetos que compartilham uma mesma estrutura descritiva. As relações entre objetos, classes e atributos são apresentadas no modelo orientado a objeto, de acordo com esquema da Figura 10.

Cada atributo terá uma variação de valores (numérico, ordinal, nominal) . A estrutura de atributos dos objetos é determinada pela classe a que pertencem. Assim, cada objeto tem uma lista contendo um valor para cada atributo da sua classe, Figura 11. Uma classe  $K$  qualquer (ex.: *várzea*, *capoeirinha*, *eucalipto*, etc.) será composta por  $x_n$  objetos, de tal forma que o objeto  $O_i \in K$ .

FIGURA 11- RELAÇÕES ENTRE CLASSES, OBJETOS E ATRIBUTOS



FONTE: Adaptado MOLENAAR, 1988.

A segmentação resulta em objetos (vetor) com relações topológicas. Os objetos possuem parâmetros espectrais e não espectrais, que contribuem na distinção entre classes de objetos dentro de uma estrutura semântica determinada.

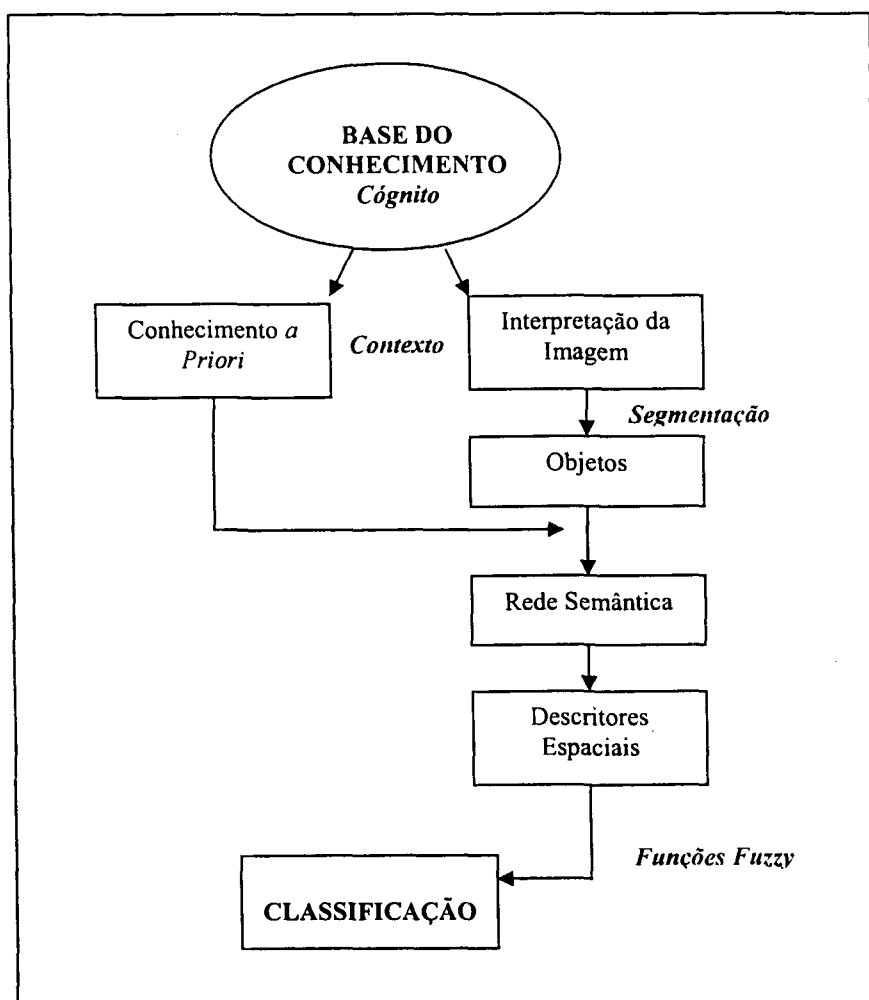
O objeto pode ser descrito por suas características próprias (atributos), ou ainda pode ser descrito através de relações com outros objetos (ANEXO 3). As relações entre objetos estão baseadas em propriedades topológicas. No processo de classificação orientado a objetos ambas descrições são utilizadas .

O modelo de dados proposto aplica-se à análise temática baseada na estrutura vetorial dos objetos. A informação multiespectral incorporada ao banco de dados permite que dados vetoriais possam ser processados e analisados de forma mais rápida que em nível de pixels. No modelo da Figura 12, observa-se que a base do conhecimento divide-se entre o conhecimento prévio e o dos dados disponíveis (imagem, vetores, etc). A imagem após a

segmentação, passa a ser vetorial com atributos que permitem construir uma estrutura semântica onde os descritores são passíveis de associação a regras de lógica fuzzy, o que possibilita a análise de contexto.

O conhecimento pode ser, então, inserido através da estrutura geométrica e temática dos objetos baseados nas suas relações espaciais.

FIGURA 12- MODELO CONCEITUAL DA CLASSIFICAÇÃO ORIENTADA A OBJETO



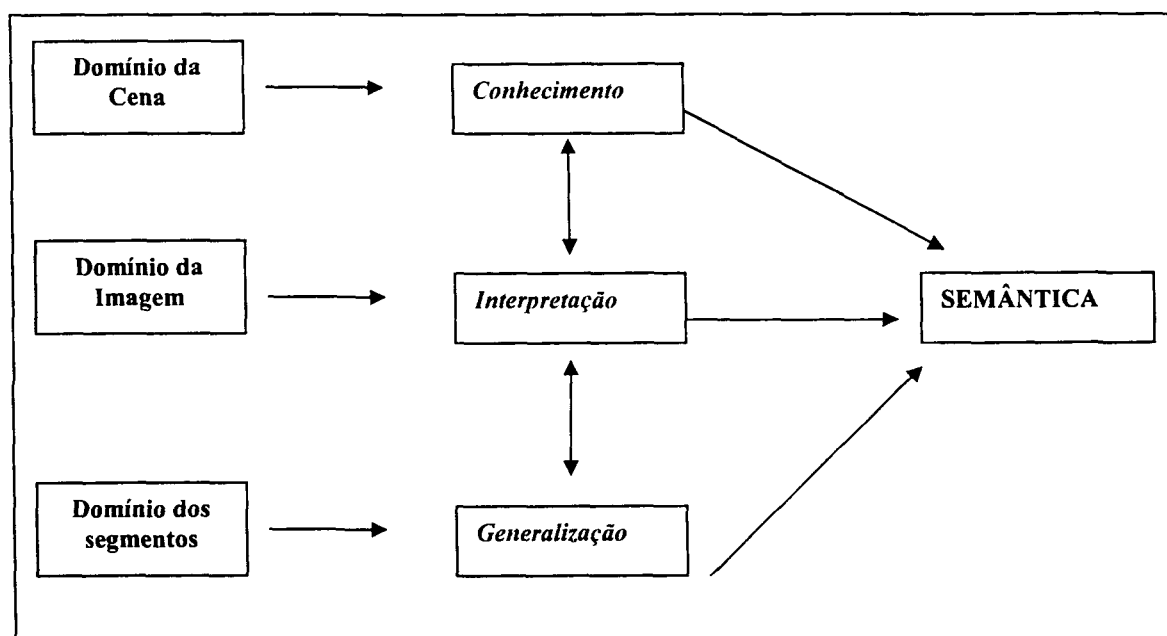
Considerando o raciocínio espacial tendo como base o objeto, o aspecto semântico de cada objeto no terreno (espaço geográfico) pode ser avaliado de acordo com suas

propriedades geométricas e temáticas. Neste trabalho as propriedades são apoiadas na forma, posição e tamanho, além de outros parâmetros derivados destes fatores, Figura 12.

#### 4.2.2- Interpretação da Imagem

O método de interpretação adotado é baseado no modelo proposto KANADE (1981) e utilizado por QUINT (1997) e BÜCKNER et al. (1999), no qual a interpretação da imagem é fundamentada em três domínios, o domínio da cena, o domínio da imagem e o domínio dos segmentos (Figura 13).

FIGURA 13- DOMÍNIOS DE INTERPRETAÇÃO



##### 4.2.2.1- Domínio da cena e da imagem

O domínio da cena representa o ambiente do mundo real, ao passo que domínios da imagem e dos segmentos envolvem a representação simplificada do mundo real. Tal modelo é uma adaptação do modelo apresentado por QUINT (1997) e BÜCKNER et al. (1999). No

domínio da cena se faz uma leitura do ambiente baseado no conhecimento inserido no determinado ambiente. No domínio da imagem as feições podem ser avaliadas e comparadas com as variações de forma, textura, orientação e tonalidade dos pixels. As feições não possuem limites rigorosamente determinados, os quais são uma aproximação dos limites reais.

A Figura 13 apresenta o esquema proposto de interpretação. Parte-se do pressuposto de um conhecimento *a priori* da realidade através de dados de campo. A interpretação no domínio da imagem é baseada nos princípios da fotointerpretação convencional, onde se consideram os elementos de cor, tonalidade, textura e forma na detecção de diferentes feições. A base do conhecimento adquirida pelo fotointérprete está vinculada ao domínio da imagem.

A interpretação resulta no delineamento de limites entre as classes (objetos), tendo em conta o conhecimento do observador no domínio da cena, e de descritores espaciais no domínio dos segmentos (ANEXO 3). A interpretação é, em geral abstrata, e traz consigo todo um processo cognitivo. Evidencia-se na imagem uma simplificação da realidade tanto ao nível de conhecimento quanto ao nível dos padrões representados pela imagem multiespectral. O resultado é a resposta à pergunta “*O que é isto?*”.

#### **4.2.2.2- Domínio dos segmentos**

O domínio dos segmentos serve como apoio à interpretação da imagem. Supondo que exista determinada incerteza na interpretação visual de determinada feição da imagem, o segmento que a representa pode ser discriminatório.

O domínio dos segmentos tem um importante papel como complemento à interpretação visual da imagem. Apesar dos milhares de objetos com diferentes configurações e orientações que constituem o domínio dos segmentos, o cérebro humano pode ainda reconhecê-los através da percepção visual. Esta percepção organizacional está baseada em




estímulos de proximidade, similaridade, simetria e continuidade (FISCHLER & FIRSCHEIN, 1987).

Assim como a semiologia gráfica permite representar o conhecimento por meio de símbolos, a interpretação dos segmentos segue um caminho similar, ou seja, as variáveis visuais de cor, forma, textura, padrão e tamanho inerentes aos objetos podem conduzir à certa significância, como por exemplo, áreas de reflorestamento de *eucalipto* no domínio dos segmentos são representadas por formas geométricas regulares, enquanto áreas de *pastagem* podem ser percebidas por padrão paralelo. Por conseguinte, enquanto os símbolos na representação cartográfica expressam determinada semântica, os objetos de uma imagem podem ser ponto de partida para sua concepção.

De acordo com BERTIN (1983), a variação de forma é associativa e pode ser considerável no que se refere à percepção de elementos similares. Da mesma maneira, a variável visual cor e textura permitem uma percepção seletiva, ou seja, a distinção de grupos de objetos. A “chave” da interpretação dos objetos implica na observação dessas variáveis (forma, cor e textura) e do conhecimento adquirido nos domínios da imagem e dos objetos. A forma alongada dos objetos do exemplo mostrado na Figura 14 permite associar as similaridades e, de maneira análoga, a cor permite salientar a distinção entre grupos de objetos.

FIGURA 14- PERCEPÇÃO ASSOCIATIVA E SELETIVA BASEADA NA FORMA E COR DOS OBJETOS



Considerando vários níveis de segmentação (objetos e subobjetos) o conhecimento pode ser também adquirido a partir das relações entre objetos primitivos que geram objetos maiores, num processo de generalização geométrica. Este processo relaciona o comportamento de pequenos objetos que possuem características similares de forma, cor e textura com os superobjetos. Exemplificando: dois objetos só serão agrupados em um objeto maior se possuírem propriedades comuns (item 4.1).

No domínio de segmentos é possível perceber os diferentes graus de generalização. Começa-se por uma segmentação, a menor possível de objetos homogêneos, e a partir desta base pode-se re-segmentar a imagem em objetos maiores. Este procedimento facilita o entendimento das relações entre os objetos da imagem, tendo em vista que os segmentos podem ser considerados como a delimitação aproximada das feições da imagem.

No que se refere à área de estudo desta pesquisa o nível mais detalhado de segmentação (fator escala) foi baseado no número mínimo de classes identificadas na imagem e que satisfaça o processo de multi-segmentação. Em um nível mais detalhado, foi evitada a obtenção de objetos demasiadamente pequenos (próximo ao pixel) de difícil discriminação.

#### **4.2.3- Rede Semântica**

##### **4.2.3.1- Conceito**

A rede semântica é expressa por uma notação gráfica representando o conhecimento por meio de *nós* e *arcos* ou *ligações* (LEHMANN, 1994; SOWA, 2000). Os nós são implementados como elementos que possuem atributos. A sintaxe da rede distingue entre dois tipos de nós: *conceito* e *ocorrência*. O *conceito* descreve o modelo genérico dos objetos. As *ocorrências* são as realizações do conceito da cena. As ligações ou arcos estabelecem as relações entre os objetos. As principais ligações são: *ocorrência\_de (instance\_of)*; *tipo\_de*


(*is\_a*); *parte\_de* (*part\_of*). A Figura 15 mostra as ligações *parte\_de* que descrevem a classe *ambiente ciliar* como parte da superclasse *floresta*. As classes *várzea* e *galeria* são uma especialização de floresta, portanto herdam suas características.

Baseado no procedimento multi-resolução proposto por BAATZ & SCHÄPE (1999), os objetos possuem atributos, propriedades e valores, existindo ocasionalmente herança entre os objetos. Num primeiro momento se estabelecem relações associativas que se referem à organização do conhecimento que pode não ser baseada em regras determinísticas. Num segundo momento se desenvolve um conhecimento predicativo que descreve relações mais exatas entre os *nós*.

#### 4.2.3.2- Estruturação da rede

Neste trabalho, a regra adotada é a da especialização onde se parte do geral, segmentos maiores (superobjetos), até o maior grau possível de interpretação (subobjetos). Este é um processo puramente cognitivo e, conseqüentemente abstrato, contudo é mais próximo à percepção humana. Começa-se de uma visão genérica da imagem até atingir a especificidade pretendida. A partir desta avaliação é factível criar uma estrutura semântica baseada em hierarquia.

FIGURA 15- LIGAÇÕES ENTRE OS NÓS



A hierarquia de objetos resultante da segmentação multi-resolução é uma maneira de formular a base do conhecimento para a classificação dos objetos. Todas as classes são hierarquicamente estruturadas. Os descritores dos superobjetos são repassados aos subobjetos. De maneira análoga, a hierarquia de grupos pode agregar diferentes classes a uma classe superior que possua o mesmo significado semântico. A Figura 15 mostra a superclasse de *vegetação* e as subclasses *galeria* e *várzea*, sendo que estas herdam os descritores da classe superior à que pertencem. Este procedimento permite a formulação de uma rede semântica que por sua vez permite descrever relações entre os objetos baseados no contexto. O conhecimento proveniente de outras fontes de dados pode ser inserido de forma a discriminar um maior número de classes.

A cena em que as classes estão inseridas está diretamente relacionada à percepção da existência das mesmas, por que, onde e como ocorrem. A conexão entre a realidade de campo e a imagem é o primeiro passo no processo de interpretação e estabelecimento de relações entre os objetos. A complexidade das relações entre os objetos pode restringir a capacidade do usuário em generalizar a informação. As incertezas serão tão maiores quanto maior for o nível de detalhes e, da mesma maneira, a existência excessiva de superobjetos pode conduzir à perda de informação relevante.

Considera-se que a interpretação da imagem possui determinado grau de incerteza, logo, é possível também aceitar outras possibilidades de classificação para o mesmo objeto, uma vez que o relacionamento topológico está presente. A relatividade temática é uma constante no processo de classificação.

Um conceito chave no processo de classificação baseada em rede semântica é o entendimento da dependência espacial entre as classes, a autocorrelação espacial. Estas noções partem do que Waldo Tobler chama de "a primeira lei da geografia", citado por

BAATZ et al. (2001) : "*todas as coisas são parecidas, mas coisas mais próximas se parecem mais que coisas mais distantes*". Este princípio parte do pressuposto das interdependências entre as classes, que nada na natureza (como na vida real) ocorre por acaso. O fenômeno de autocorrelação espacial pode ser entendido como uma situação em que observações próximas no espaço possuem valores similares (correlação de atributos). A segmentação multi-resolução de certa forma explicita a correlação entre os objetos e, conseqüentemente, permite a inserção da semântica dos objetos.

São definidos dois tipos de contexto: (1) contexto dos objetos relacionado à vizinhança e relações topológicas e (2) contexto temático referente ao ambiente onde ocorrem as classes ex.: *mata de galeria* e *várzea*.

A definição e a identificação de objetos elementares segue a sua especificação temática expressa através do sistema de classificação, dentro do qual o contexto e decisão devem ser realizados.

A *várzea* depende da área de inundação permanente e a vegetação de galeria, adjacente, ocorre nas áreas menos inundáveis. Contudo, o aparecimento de fatores antrópicos faz com que as regras de transição sejam quebradas e outros fatores de inferência sejam considerados. As regras de classificação dos objetos devem considerar o conhecimento *a priori* do objeto, e sua ocorrência na imagem. A princípio as classes de *várzea* e *agricultura* podem ser compostas por objetos com respostas espectrais muito similares, contudo a discriminação entre ambas depende de fatores fora do âmbito espectral. A Tabela 1 mostra as principais diferenças em termos de conhecimento *a priori* de três classes espectralmente próximas entre si.

TABELA 1- CARACTERÍSTICAS DAS CLASSES DE VÁRZEA, AGRICULTURA E MATA DE GALERIA.

CLASSES	FATORES DO AMBIENTE			ESPECTRAL
Várzea	Solo (alagado)	Proximidade com leito do rio	Áreas baixas	Baixa discriminação entre as classes.
Agricultura	Solo (irrigado)	Áreas abertas	Áreas menos baixa	Respostas espectrais próximas entre si
Mata de Galeria	Solo pouco Alagável	Adjacente à várzea	Ao longo do Rio	

Tendo em vista que as classes acima citadas são spectralmente próximas entre si, o ambiente no qual elas ocorrem exercem um papel preponderante na descrição da sua semântica.

#### 4.2.3.3- Formalização da Hierarquia

Algumas classes podem possuir atributos em comum, e observa-se que quando uma classe de nível superior ou superclasse é definida (classe mãe), esta em geral possui atributos que são comuns a outras classes. Classes inferiores estão subordinadas à classe superior, como por exemplo, a classe ambiente ciliar contém as subclasses *várzea* e *mata de galeria*. O objeto que está subordinado à classe *várzea* também estará subordinado a classe *ambiente ciliar*. É factível a formação de grupos de objetos de características espectrais e semânticas similares.

Supondo-se  $C_s$  a classe superior ou superclasse, de um subconjunto do universo  $U$ , e  $C_k$  subconjunto de  $C_s$ .  $O_i$  é um objeto membro da classe  $C_k$ . Se  $O_i \in C_k$ , isto implica que  $O_i$  é membro da classe  $C_s$ , tal que:

$$O_i \in C_k \text{ e } O_i \in C_s, \text{ então } C_k \subset C_s \quad (1)$$

Classes superiores podem ter várias classes de níveis inferiores, porém as inferiores podem estar relacionadas tão somente a classe diretamente acima.

Seja  $\Pi = \{ P_1, P_2, \dots, P_p \}$ , onde  $P$  são as sub-divisões (níveis) de uma coleção de objetos  $\Pi$ , de forma que cada sub-divisão contém um nível hierárquico,  $k$ , tal que:

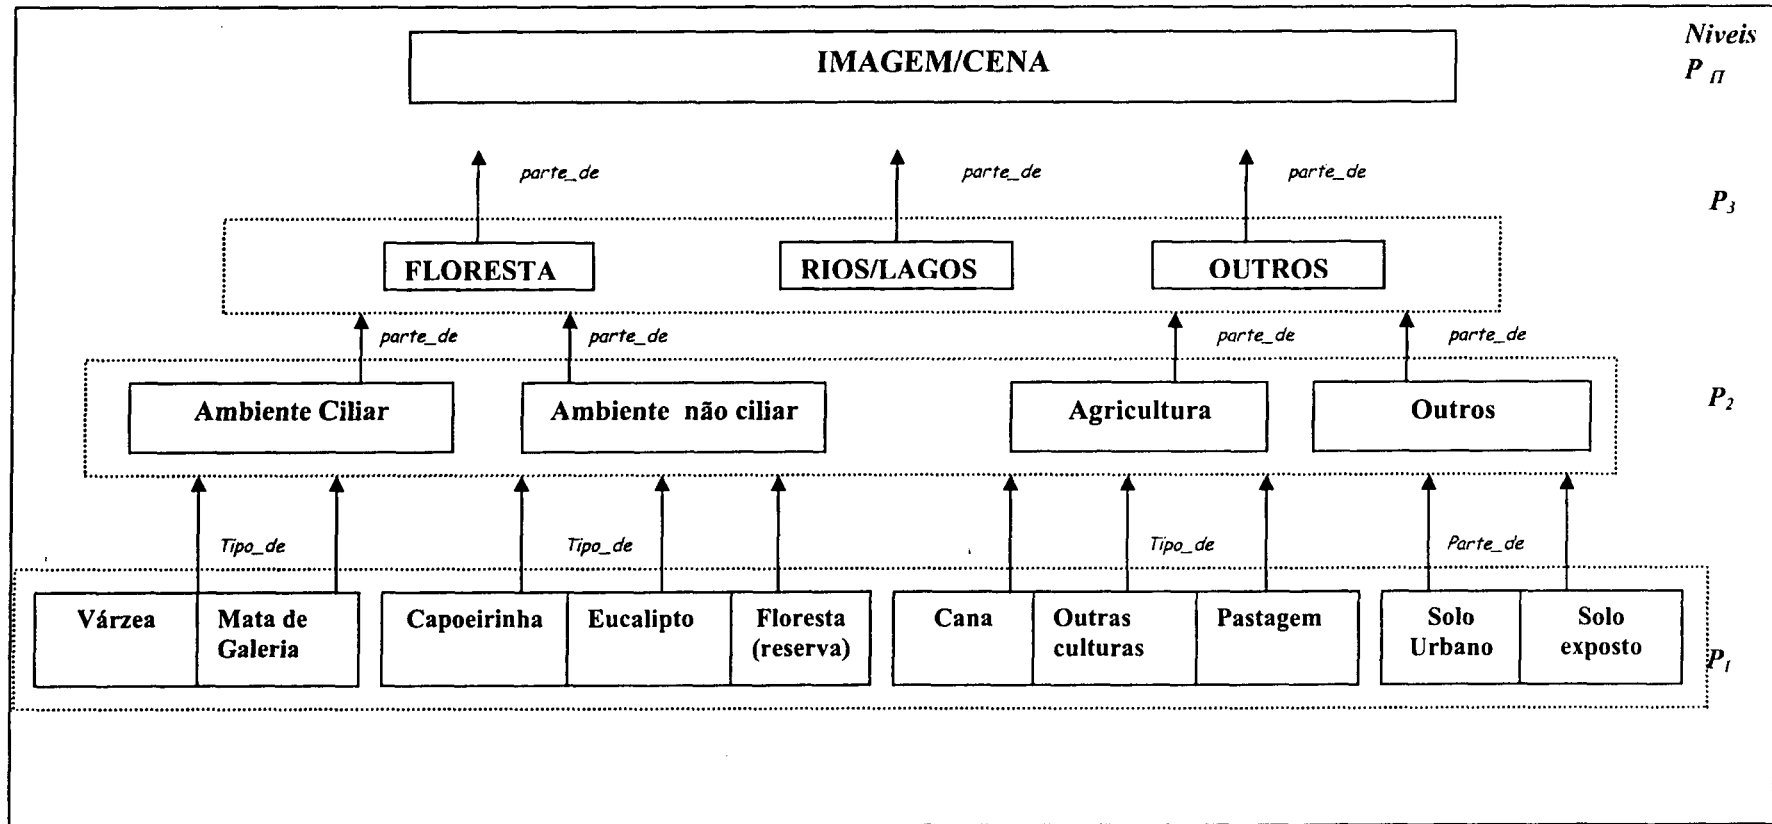
$$C_i \in P_k \mid k < \pi ; \exists C_j \in P_{k+1} ; C_i \subseteq C_j \quad (2)$$

A expressão (2) acima implica que os conjuntos da coleção  $\Pi$  estão ordenados, de forma que cada conjunto contenha classes num determinado nível de hierarquia, onde,  $P_\pi$  é o maior nível de hierarquia e  $P_1$ , o menor (Figura 16).

Na Figura 16 o nível mais alto de hierarquia começa com discriminação entre objetos baseados em seus atributos (*Floresta, Água, Outros*). As relações entre os nós são realizadas por um processo de especialização baseada em ligações semânticas tipo: *parte\_de* e *é\_o\_ou\_um\_tipo\_de*. O *ambiente não ciliar* (nível  $P_2$ ), faz parte de *floresta*, porém *ambiente não ciliar* pode não ser um tipo de *floresta*. Por outro lado, no esquema proposto, *capoeirinha, eucalipto e remanescente de floresta* longe do leito do rio representam um tipo de *ambiente não ciliar*, em um nível mais detalhado ( $P_1$ ).

A rede semântica proposta na Figura 16 é baseada no conhecimento *a priori* das feições do terreno e suas características no domínio da imagem. A representação do conhecimento por meio da semântica pode ser estendida a outras áreas da imagem com características fitogeográficas semelhantes. Uma vez que a rede é testada em uma outra área, torna-se mais concreto o arcabouço das relações entre os objetos. Pretende-se, então, avaliar a aplicabilidade da rede semântica nas cercanias da área de estudo.

FIGURA 16- NÍVEIS HIERÁRQUICOS- ESTRUTURA SEMÂNTICA





### 4.3- CLASSIFICAÇÃO

Primeiramente é feita uma abordagem da classificação fuzzy ao nível de pixel com o método convencional de máxima verossimilhança e posteriormente procede-se a comparação com o método proposto de orientação a objeto.

A classificação proposta é baseada em níveis hierárquicos de objetos inter-relacionados (Figura 16). Numa primeira etapa, o conhecimento é representado por uma rede semântica, criada a partir de um arcabouço hierárquico. A seguir, são introduzidas as funções de pertinência fuzzy apoiadas nos seguintes descritores: espectral, forma e textura, de acordo com a especificidade de cada feição. A categorização dos objetos é dada pelo grau de pertinência de um objeto à uma classe específica. A existência de determinada classe pode depender de diferentes funções de pertinência.

#### 4.3.1- Classificação fuzzy ao nível de pixel

Um conjunto fuzzy é caracterizado por sua função de pertinência (item 3.5). A fim de dividir em partes o espaço espectral, funções de pertinência devem ser definidas para cada classe. As funções de pertinência, deste método, são baseadas nas funções densidade de probabilidade do algoritmo de máxima verossimilhança (maxver). A média e a matriz variância-covariância do método máxima verossimilhança são substituídas pela média e matriz variância-covariância fuzzy. O método descrito a seguir é baseado na proposição de WANG (1990).

Define-se o espaço espectral fuzzy como uma família de conjuntos fuzzy,  $F_1, F_2, F_3, \dots, F_m$ , no universo  $X$ , tal que:

$$\forall x \in X; 0 \leq f_{Fi}(x) \leq 1;$$

$$\sum_{i=1}^m f_{Fi}(x) = 1 \quad (1)$$

onde:

$X$  é o total de pixels;

$m$  é o número de classes;

$x$  é o vetor observação

$f_{Fi}$  é a função de pertinência do conjunto tal que  $F_i$  ( $1 \leq i \leq m$ ).


O espaço fuzzy pode ser representado por uma matriz de partição onde  $n$  é o número de pixels e  $x_i$  são os pixels ( $1 \leq i \leq n$ ).

$$\begin{pmatrix} f_{F1}(x1) & f_{F1}(x2) & f_{F1}(x3) & f_{F1}(xn) \\ f_{F2}(x1) & \dots & \dots & f_{F2}(xn) \\ f_{F3}(x1) & \dots & \dots & f_{F3}(xn) \\ \vdots & \vdots & \vdots & \vdots \\ f_{Fm}(x1) & f_{Fm}(x2) & f_{Fm}(x3) & f_{Fm}(xn) \end{pmatrix}$$

Na partição convencional da matriz acima, o valor máximo de cada coluna seria “1” e os restantes completados por zero. No espaço espectral fuzzy a situação real é mais bem representada, pois valores de pertinência variáveis podem ser associados à classes intermediárias. O espaço espectral apresenta-se não repartido em superfícies com limites bem definidos, mas sim por limites intermediários (Figura 17).

As funções de pertinência são derivadas a partir de amostragem (áreas de treinamento) das classes na imagem. Os parâmetros estatísticos oriundos da amostragem possuem fundamental importância no delineamento das funções. EASTMANN (1997) salienta que a representação fuzzy torna possível determinar parâmetros estatísticos próximos dos reais, por meio da determinação de probabilidades fuzzy.

FIGURA 17- PARTIÇÃO DO ESPAÇO ESPECTRAL E SUPERFÍCIES DE DECISÃO



FONTE: Adaptado de WANG, 1990<sup>a</sup>.

Seja  $P(A)$  a probabilidade de ocorrer um evento  $A$ , no espaço amostral  $\sigma$ :

$$P(A) = \int_{\sigma} XA(x) dP \quad (2)$$

Onde :

$A$  é um conjunto definido pelos pontos em  $\sigma$ ;

$x$  denota o ponto em  $\sigma$ ,

$XA$  a função  $A(XA(x)=0$  ou  $1$ ).

Considerando  $A$  um evento fuzzy, o conjunto dos pontos no espaço  $\sigma$ , a probabilidade em  $A$  pode ser definida como:

$$P(A) = \int_{\sigma} f_A(x) dP \quad (3)$$

Onde  $f_A(x)$  é a função de pertinência de  $A$  ( $0 \leq f_A(x) \leq 1$ ).

Similarmente a média e variância de uma amostragem fuzzy relativo à probabilidade  $P$

podem ser expressas por:

$$\mu_A = 1 / P(A) \int_{\sigma} x f_A(x) dP \quad (4)$$

$$VA = 1 / P(A) \int_{\sigma} (x - \mu_A)^2 f_A(x) dP \quad (5)$$

As equações da variância e média (equações 4 e 5) explicitam que, quanto mais um pixel pertence a determinado evento, mais este contribui para média e variância do evento. A equação da média (4), pode ser re-escrita para uma amostra de uma classe  $c$  qualquer, representado como conjunto fuzzy:

$$\mu_c = \sum_{i=1}^n f_c(x_i) x_i + \sum_{i=1}^n f_c(x_i) \quad (6)$$

Da mesma forma a matriz covariância fuzzy será dada por:

$$Cov = \sum_{i=1}^n f_c(x_i) (x_i - \mu_c)^2 (x_i - \mu_c)^T + \sum_{i=1}^n f_c(x_i) \quad (7)$$

Onde:

$n$  é o total de pixels amostrados,  
 $f_c$  é a função de pertinência para classe  $c$   
 $x_i$  é o vetor de observação.

Na média fuzzy para classe  $c$ , o vetor observação  $x$  é multiplicado pelo grau de pertinência em  $c$   $f_c(x)$  antes do somatório. Similarmente, o mesmo ocorre com a covariância.

A amostragem fuzzy (áreas de treinamento) para classificação supervisionada difere da convencional. A tendência de homogeneidade é menos importante e uma área de treinamento pode ser usada para gerar parâmetros estatísticos para mais de uma classe.

As funções de pertinência podem ser adaptadas pelas funções densidade de probabilidades (máxima verossimilhança) utilizando média e matriz covariância fuzzy.

Logo, seja:

$$f_c(x) = P^{fz}_c(x) / \sum_{i=1}^m P^{fz}_i(x) \quad (8)$$

Onde,  $f_c(x)$  da classe  $c$  (WANG, 1990b):

$P^{fz}$  é dado pela equação (8)

$$P^{fz}_c(x) = \{1/(2\pi)^{N/2} |Cov_c|^{-1/2} \exp[-1/2(x-\mu_c)^T Cov_c^{-1} (x-\mu_c)]\} \quad (9)$$

Onde:

$N$  é a dimensão do vetor observação,

$m$  número de classes.

$P^f_c(x)$ , probabilidade fuzzy,

$Cov_c$  matriz covariância fuzzy.

O grau de pertinência do vetor observação,  $f_c(x)$ , depende da posição  $x$  no espaço espectral.  $f_c(x)$  aumenta exponencialmente com o decréscimo da distância de Mahalanobis  $((x - \mu_c)^T Cov_c^{-1} (x - \mu_c))$ , entre  $x$  e a classe  $c$ . A expressão  $\sum_{i=1}^m P_i^f(x)$ , funciona como um fator de normalização.

#### 4.3.2- Classificação ao nível dos objetos- Regras Fuzzy

Os descritores fuzzy (ANEXO 3) permitem gerar funções de pertinência que refletem o conhecimento. A mais simples regra fuzzy pode ser criada baseada num simples descritor. Por exemplo, um objeto pode ser classificado como a classe água utilizando o descritor média espectral para ser definido como um conjunto fuzzy. Formula-se a regra fuzzy representando o conhecimento por meio da relação entre os valores notáveis do descritor (item 3.5, Figura 6).


**‘Se média\_espectral (objeto)  $\in \mu_{\text{média}}$  então, classe<sub>(objeto)</sub> = água’;**

Um objeto pode estar associado a várias classes com diferentes graus de pertinência. O grau de pertinência  $\mu_{\text{soloexposto}} = 0,7$ , exprime a maior possibilidade do objeto pertencer à classe *solo exposto*, logo a decisão adequada seria enquadrar o objeto como membro da classe solo, embora existam evidências menores a favor de outras classes: *agricultura* (0,5); *várzea* (0,2), Figura 18.

Diferentes funções de pertinência que associam um objeto à determinada classe podem ser originadas de diferentes fontes (ex: informações temáticas, modelo digital do terreno). A

combinação de diferentes conjuntos fuzzy vai depender de diferentes operadores. Os operadores básicos são E e OU. O operador E representa o valor mínimo de todos os conjuntos, enquanto o operador OU representa o valor máximo para os conjuntos em questão. Considerando dois conjuntos fuzzy  $\text{Min}(\mu_A(x); \mu_B(x))$  é empregado para intersecção dos conjuntos ao passo que  $\text{Max}(\mu_A(x); \mu_B(x))$  é empregado para união dos conjuntos.

FIGURA 18- EXEMPLO DE GRAUS DE PERTINÊNCIA.



FONTE: Adaptado de DEFINIENS IMAGENG, 2003

Pode também haver uma combinação de condições fuzzy;

**‘Se (média espectral (objeto)  $\in \mu_{media}$ ) E ( comprimento (objeto)  $\in \mu_{comprimento}$ ), então, classe(objeto) = rio’;**

Como o operador “intersecção” é utilizado na declaração acima, o grau de pertinência para classe *rio* é igual ao mínimo valor de duas pertinências:

$$\mu_{rio}(\text{objeto}) = \text{MIN}((\mu_{media}); (\mu_{comprimento}))$$

O resultado desta regra fuzzy poder ser inserido numa próxima regra, assim uma estrutura hierárquica pode ser criada baseada em determinada semântica. Por exemplo, uma regra define *ambiente ciliar*, uma outra regra define *várzea*, dentro da classe *ambiente ciliar*.

$$(1) \mu_{ambiente\ ciliar}(\text{objeto}) = \mu_{banda\ 4}(\text{valor\ médio\ do\ layer}(\text{objeto}));$$

$$(2) \mu_{varzea}(\text{objeto}) = \text{MIN}(\mu_{ambiente\ ciliar}(\text{objeto}); \mu_{várzea}(\text{razão}(\text{objeto})));$$

A hierarquia permite definir uma subclasse várzea caracterizada pelo descritor razão (*ratio*, Tabela 2). As regras fuzzy são explicitadas utilizando as ferramentas disponíveis no software *e-cognition* (*FNEA fractal net evolution approach*).

#### 4.3.3- Descritores

Para a classificação baseada em regras fuzzy são utilizados neste trabalho os descritores baseados em parâmetros espectrais e de forma.

##### 4.3.3.1- Descritores baseados em valores espectrais

Alguns parâmetros baseados nos valores espectrais das bandas 1, 2, 3 e 4 do Ikonos, são extraídos de acordo com as expressões da Tabela 2 abaixo (BAATZ et al., 2001).

TABELA 2- DESCRITORES BASEADOS EM VALORES ESPECTRAIS DAS BANDAS (1,2,3,4).

PARÂMETROS	EXPRESSÃO MATEMÁTICA	DESCRIÇÃO
Média	$C_L = \frac{1}{n} \cdot \sum_{i=1}^n C_{Li}$	Valor médio calculado a partir de todos os pixels em uma determinada banda, dividido pelo somatório dos pixels que formam um segmento. Onde: $C_L$ = valor médio calculado; $n$ = número de pixels que formam o objeto; $C_{Li}$ = valor médio do pixel "i" na banda "L".
Brilho	$b = \frac{1}{n_L} \cdot \sum_{i=1}^{n_L} C_i$	Soma do valor médio de todas as bandas espectrais, divididos pelo número de bandas espectrais que formam um segmento. Onde: $b$ = valor médio de todas as bandas; $n_L$ = número de bandas espectrais; $C_i$ = valor médio da "i".

TABELA 2- Continuação

PARÂMETROS	EXPRESSÃO MATEMÁTICA	DESCRIÇÃO
Razão	$r_L = \frac{C_L}{\sum_{i=1}^{n_L} C_i}$	<p>A razão de uma banda qualquer é o valor médio desta banda, dividido pela soma dos valores médios de todas as bandas espectrais que formam um segmento. Descreve a predominância de uma determinada banda em relação às demais.</p> <p><math>r_L</math> = relação de uma banda qualquer "L";  <math>C_L</math> = valor médio de uma banda qualquer "L";  <math>C_i</math> = valores médios de todas as bandas espectrais .</p>
Diferença média entre objetos vizinhos	$\Delta\mu_b = 1/l \cdot \sum_{i=1}^n l_{si} (\mu_b - \mu_{bi})$	<p>Para cada objeto vizinho é determinada a diferença média em determinada banda, proporcionalmente ao comprimento limite entre os objetos:</p> <p>Onde:</p> <p><math>\Delta\mu_b</math> é diferença média espectral entre dois objetos vizinhos;  <math>l</math> = o perímetro do objeto em questão;  <math>l_{si}</math> = o comprimento do limite com um objeto <math>i</math>;  <math>\mu_b</math> = a média para o objeto para uma banda <math>b</math>;  <math>\mu_{bi}</math> = valor médio para o pixel vizinho;  <math>n</math> = a quantidade de vizinhos.</p>

FONTE: Adaptado de BAATZ et al. 2001

#### 4.3.3.2- Descritores de forma

Em termos visuais a forma é um dos elementos mais importantes para interpretação de imagens digitais, sendo uma variável que permite percepção associativa dos objetos da imagem. Contudo, a propriedade associativa dos objetos da imagem propicia uma análise puramente qualitativa; por outro lado, a análise quantitativa é também relevante para discriminação de feições. A determinação de parâmetros de forma depende das propriedades geométricas geradas no processo de segmentação . Neste trabalho foram testados os diferentes descritores de forma relacionados na Tabela 3.

Muitos dos parâmetros de forma são baseados na estatística de distribuição espacial dos pixels que compõem um objeto. A estatística é baseada na matriz covariância.




$$M_{cov} = \begin{vmatrix} Var(X) & Cov(XY) \\ Cov(XY) & Var(Y) \end{vmatrix}$$

onde:  
 $X$  = x-coordenadas dos pixels que formam o objeto;  
 $Y$  = y-coordenadas dos pixels que formam o objeto;

Outra técnica de derivar informação sobre forma de objetos não curvos é utilizar sua geometria. A informação é dada pelo quadrado ou retângulo que contém o objeto, dados o comprimento **a**, altura **b** e o grau de preenchimento **f**. O preenchimento **f** é dado pela razão área do objeto **A** e a área da figura abrangente, produto **a.b**, Figura 19.

FIGURA 19 - PARÂMETRO DE FORMA BASEADO NA GEOMETRIA



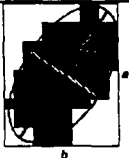
Existem duas formas segundo BAATZ & SCHÄPE (2001) BAATZ et al.(2001) de determinar a razão *comprimento/largura*  $\gamma$ . A primeira utiliza a matriz de covariância (auto valores) e a segunda aplica a geometria.

$\gamma = C/L = \text{auto-valor1}/\text{auto-valor2}$ ; utilizando a geometria tem-se:

$$\gamma = [a^2 + ((1-f).b)^2] / A;$$

onde:  
**c**= comprimento;  
**l**=largura,

TABELA 3- ÍNDICES DE FORMA

PARÂMETROS	EXPRESSÃO MATEMÁTICA	DESCRIÇÃO
Comprimento	$L = \sqrt{A \cdot \gamma}$	A= área abrangente; $\gamma$ = razão C/L
Largura	$L = \sqrt{A / \gamma}$	A= área abrangente; $\gamma$ = razão C/L
Comprimento do Limite	$Cl = \sum s_i$	Somatório dos segmentos limítrofes entre dois objetos
Índice de Forma	$S = Cl / 4 \cdot \sqrt{A}$	Expressa a suavidade do limite entre objetos. Quanto mais fractal, maior o índice de forma.
Densidade	$d = \sqrt{n} / (1 + \sqrt{VAR(X) + VAR(Y)})$	É descrito pela razão da área que cobre um objeto pelo seu raio. $n$ = o número de pixels que formam os objetos; $r$ =o raio aproximado (matriz covariância); A densidade descreve a compacidade do objeto. Quanto mais a forma de um objeto se aproxima de um quadrado maior sua densidade.
Assimetria	$As = 1 - n/m$	 É determinado de acordo com o semi-eixo maior $a$ e o semi-eixo menor $m$ de uma elipse que compreende o objeto. Quanto mais comprido um objeto, mais assimétrico. Varia de 0 a 1.
Compacidade	$Cp = 4 \cdot \pi \cdot A / P^2$	É definido pela razão área $A$ do objeto (polígono) e o raio da circunferência abrangente. Varia de 0 a 1.

FONTE: Adaptado de BAATZ et al. 2001.

#### 4.3.3.3- Relacionamentos de vizinhança

A informação para classificação de um objeto pode derivar dos seus subobjetos. Características como perímetro, área e limites comuns entre os subobjetos podem ser relevantes na discriminação de algumas classes .

Os relacionamentos entre objetos vizinhos são importantes na inserção do contexto e são baseados em relações topológicas; os objetos podem ser relacionados por limites de vizinhança, área, existência e distância (ANEXO 3). Por exemplo, um objeto pode ser

associado a uma classe se estiver próximo a ela ou se existir determinada feição. A classe como *ambiente não ciliar* só irá ocorrer a uma determinada distância do curso d'água, e analogamente, a classe de *ambiente ciliar* só existirá se existir a classe *rio*.

A existência de um objeto da imagem atribuída a uma classe pode ser definida tendo como base determinado perímetro (em pixel) em relação a uma outra classe (objetos). Se um objeto da imagem for encontrado dentro deste perímetro, o valor de pertinência é 1 (verdadeiro), se não será 0 (falso). O raio que define o perímetro pode ser determinado editando a partir de uma distância.

Alguns níveis de informação foram introduzidos a fim de se delimitar o contexto. Foram utilizados os níveis de informações vetoriais de *rios* e *estradas*. Estes níveis de informação condicionam a ocorrência de algumas classes.

#### 4.3.3.4- Textura

Num amplo sentido a textura pode ser vista como a variação do nível de cinza de uma imagem. Alternativamente, textura pode ser interpretada como cópias, simetrias e combinações de vários padrões ou funções locais que exibem determinada variação tonal. Entretanto, a descrição computacional da textura é ampla, vaga, e muitas vezes conflitante com a noção semântica percebida pelo cérebro humano (KOURGLI & BELHADJ-AISSA, 2000; KIEMA, 2001).

O método de análise de textura é bastante relevante para a classificação dos objetos, pois explora a característica espacial dos mesmos. Nesta pesquisa, a análise de textura diz respeito a relações entre subobjetos- portanto dependente de diferentes níveis de segmentação. A textura utilizada é baseada em características espectral e de forma dos subobjetos.

O desvio padrão, determinado através da expressão apresentada por IRON & PETERSON (1981), é aplicado ao nível de subobjetos. A diferença entre a análise estatística ao nível de pixel e ao nível de objetos, reside do fato de que os objetos são oriundos da segmentação pressupostamente composta por áreas homogêneas.

$$\sigma_{\lambda} = \sqrt{\sum (X_{\lambda} - \mu_{\lambda})^2 / n - 1}, \quad (1)$$

onde:

$X_{\lambda}$  = nível de cinza para banda  $\lambda$  para um subobjeto,

$\mu_{\lambda}$  = média dos subobjetos,

$n$  = número de subobjetos.

A análise de textura tanto ao nível de variação de forma como de cor é vinculada ao processo de generalização de segmentos. Pequenos objetos num nível  $P_i$  possibilitam análise de textura num nível  $P_{i+1}$ , de maior tamanho.

A textura relacionada a variação de forma pode ser importante para classificação dos objetos. De maneira geral, é possível distinguir entre textura regular de grupo de objetos referentes a obras feitas pelo homem, de textura menos regular relacionadas a feições naturais (SEBE & LEW, 2000).

#### 4.4- CONFIABILIDADE DA CLASSIFICAÇÃO

Nos mapas temáticos obtidos através da classificação digital de imagens estão inseridos erros temáticos. A acurácia e a qualidade das informações representadas na imagem devem ser estimadas, a fim de validar a eficiência do classificador adotado (ANEXO 2).

#### 4.4.1- Ambigüidade da Classificação

Muitos métodos de avaliação de acurácia têm sido discutidos na literatura. Os métodos mais utilizados, ainda hoje, são baseados na matriz de confusão ou de erros. A confiabilidade da matriz de erros depende da amostragem, registro e conhecimento (ROSENFELD & FITZPATRICK, 1982; CONGALTON & GREEN, 1999; FOODY, 2002). A matriz de erros apresentada na literatura é baseada em amostragem de pixels. LABA et al (2002) salienta que cada objeto pode possuir associação parcial a determinada classe, logo, em imagem classificada por regras fuzzy, a acurácia deveria ser avaliada em termos de grau de ambigüidade. CONGALTON & GREEN (1999) & FOODY (2002), não descartam totalmente o método tradicional de avaliação de acurácia por meio de matriz da confusão, mesmo para classificadores ditos leves.

Não existe um consenso na comunidade de sensoriamento remoto sobre qual a melhor maneira de se avaliar a acurácia da classificação oriunda de classificadores leves (FOODY 2002; LABA et al, 2002).

Introduz-se, desta forma uma metodologia de avaliação da acurácia baseada em dois parâmetros: (a) coeficiente de acurácia *Tau* determinado por meio da matriz de erros; (b) ambigüidade da classificação levando em conta os graus de pertinência.

##### 4.4.1.1- Coeficiente *Tau* de concordância

Matematicamente a matriz de erros ou confusão é representada por:

$n_{11}$	$n_{12}$	$n_{1k}$	$n_{1+}$
$n_{21}$	$n_{22}$	$n_{2k}$	$n_{2+}$
$n_{k1}$	$n_{k2}$	$n_{kk}$	$n_{k+}$
$n_{+1}$	$n_{+2}$	$n_{+k}$	$N$

$i =$  linhas;  
 $j =$  colunas;  
 $n_{+j} =$  total colunas;  
 $n_{i+} =$  total linhas

As  $k$  classes são amostradas de forma independente. Na matriz as linhas representam os objetos classificados e nas colunas os objetos de referência,  $n_{ij}$  denota o número de amostras classificadas na categoria  $i$  ( $i= 1,2,3...k$ ) na classificação da imagem e na categoria  $j$  ( $j= 1,2,3...k$ ) dos dados de referência. A matriz de erros permite a determinação de coeficientes de acurácia de *Tau* (ANEXO 2) que é uma técnica discreta multivariada e expressa a correlação entre a verdade de campo e as imagens classificadas, baseadas em probabilidades.

O coeficiente de concordância *Tau* adotado, é dado por:

$$\tau = \frac{P_o - P_r}{1 - P_r} \quad (1)$$

onde :

$P_o$  é a concordância observada;

$P_r$  é a concordância esperada.

*Tau* baseia-se na probabilidade *a priori* (MA & REDMOND, 1995; NAESSET, 1996), ou seja, a concordância esperada ( $P_r$ ) pode ser obtida antes mesmo de elaborar a matriz de erros.  $P_r$  é expresso por  $1/k$ , onde  $k$  é número de categorias ou classes. A concordância observada é expressa por:

$$P_o = \frac{\sum n_{ii}}{N}; \quad (2)$$

onde:

$n_{ii}$  são os elementos corretamente classificados

$N$  é o número total de elementos

Logo:

$$\tau = \frac{\frac{\sum n_{ii}}{n} - 1/k}{1 - 1/k} \quad (3)$$

neste caso se considera a mesma probabilidade *a priori* para todos os objetos a serem categorizados randomicamente. No caso de diferentes probabilidades,  $P_r$  também pode ser calculado baseado em diferentes probabilidades *a priori*, para cada classe.

NAESET (1996) justifica que *Tau* pode ser mais interessante que o coeficiente *Kappa* (largamente utilizado pela comunidade de Sensoriamento Remoto) no que se refere à correta estimação de concordâncias ao acaso. Resultados empíricos mostram que *Kappa* tende a superestimar as chances de concordância e subestimar a acurácia da classificação.

#### 4.4.1.2 Ambigüidades

A matriz de erro pode ser pouco representativa quando as categorias são originárias de classificação baseada em lógica fuzzy. Outra maneira de avaliar a qualidade do mapa temático é na análise de sua própria gênese. O esquema de classificação apresentado possui dois componentes: (1) a semântica; (2) as regras. Trabalha-se com a possibilidade de um objeto  $O_i$  qualquer pertencer a uma classe  $c$ . Os valores de pertinência não são probabilidades. Por esta razão, um alto grau de pertinência para um objeto pertencer a uma classe não significa exatamente sua categorização para esta classe.

No que se refere a confiabilidade da classificação é interessante avaliar os graus de pertinência dos objetos que os associam com determinada classe. Um objeto  $O_i$  qualquer pode possuir diferentes graus de pertinência para diferentes classes. O objeto, geralmente, é associado à classe cujo grau de pertinência é maior. Contudo, graus de pertinência próximos mostram certo grau de incerteza, ou instabilidade, o que pode possibilitar a indução de erros de categorização. Uma prerrogativa da classificação por meio de regras fuzzy é a perspectiva de avaliar imprecisão por meio das diferentes possibilidades de classificar um objeto  $O_i$ . Propõe-se para a determinação do grau de ambigüidade a seguinte expressão:

$$I_a = (b_{c1} - b_{c2}) / b_{c1} \quad (1)$$

Onde :


$b_{c1}$  = maior grau de pertinência para uma classe  $c_i$  qualquer ;

$b_{c2}$  = segundo maior grau de pertinência para uma classe  $c_j$  qualquer;

$c_i \neq c_j$

A instabilidade da classificação pode ser determinada a partir da razão da diferença dos dois maiores graus de pertinência pelo maior grau de pertinência. A Figura 20 mostra os diferentes valores em diferentes situações. Os valores de  $I_a$  variam de 0 a 1. O valor 1 indica que não há incerteza na associação de um objeto a determinada categoria e valor nulo indica total incerteza. Na Figura 20 exemplifica-se o cálculo das ambigüidades para as classes de *agricultura*, *solo exposto* e *várzea*.

FIGURA 20- GRÁFICOS DE AMBIGUIDADE



FONTE: Adaptado BAATZ et al., 2001

Existe uma correlação entre a ambigüidade da classificação e o índice multivariado de concordância *Tau*. Entretanto, devido ao fato das regras de classificação serem fuzzy, o coeficiente *Tau* isoladamente possui significância relativa.



#### 4.4.2- Potencial de Discriminação

A imagem é uma abstração da realidade onde apenas características espectrais estão representadas, logo, é uma simplificação da realidade. Dependendo da técnica utilizada à extração de padrões, pode-se incrementar ou reduzir o poder de discriminação.

Denomina-se de potencial de discriminação ou resolução temática, o número máximo de classes que podem ser extraídas de uma imagem de acordo com o método de classificação adotado. O potencial temático depende não apenas da resolução espacial e espectral da imagem, mas também do contexto. Números adicionais de bandas derivadas tal como textura ou modelo do terreno podem sobremaneira realçar e discriminar algumas feições (RICHARDS & JIA, 1999).

O potencial de discriminação refere-se ao número de classes distinguíveis. É um valor relativo, pois sempre deve estar associado a diferentes modelos de extração de dados.

Pode ser expresso por:

$$P_d = n_a - n_b ;$$

sendo:

$n_a$  o número de classes utilizando um classificador a

$n_b$  o número de classes para um classificador b.

O valor de  $P_d$  é função do classificador da resolução da imagem. Tomando como exemplo uma imagem Landsat com 30 metros de resolução espacial, a avaliação do potencial de discriminação faz pouco sentido, pois resolução espacial restringe a especialização da imagem, independentemente do classificador adotado.

É interessante a adoção de um modelo que permita extrair da imagem um maior número possível de classes baseado no conhecimento. A hierarquia de classes proposta no modelo orientado a objeto pode conduzir a uma especialização bastante apurada, aumentando

o potencial discriminatório. Pretende-se avaliar o potencial discriminatório para diferentes metodologias de classificação tanto ao nível de pixel, como ao nível de objeto.

O grau de especialização, no entanto, só passa a ter significância se possuir determinado grau de concordância com o terreno. Não existe um limite específico para a especialização das classes dentro de uma estrutura hierárquica. Contudo, a ambigüidade tende a aumentar à medida que as características espectrais de contexto ficam cada vez mais restritas.

#### 4.4.3- Coeficiente de Contingência Cramer's V

Considerando que a classificação baseada em níveis hierárquicos possibilita diferentes resultados para a classificação de uma imagem de acordo com o contexto temático adotado, torna-se necessário mensurar o grau de consonância entre diferentes resultados obtidos para uma mesma área.

EASTMANN (1997) sugere o coeficiente de correlação de Cramer, que é baseado da estatística de Qui-Quadrado  $\chi^2$ ,

$$\text{seja : } \chi^2 = (o_1 - e_1)^2 / e_1 + (o_2 - e_2)^2 / e_2 + \dots (o_i - e_i)^2 / e_i \quad (1)$$

Onde:

$o_i$  freqüências observadas;

$e_i$  freqüências esperadas.

$\chi^2 = 0$  as freqüências teóricas e observadas coincidem exatamente, se  $\chi^2 > 0$  existe diferença entre ambas. Quanto maior o valor  $\chi^2$  maior será a discrepância entre as freqüências observadas e esperadas.

O coeficiente de Cramer's V utiliza Qui-quadrado e mede o grau de afinidade entre os atributos dos objetos de duas tabelas (imagem). Para uma tabela  $k \times k$  ( $2 \times 2$ ) é dado pela expressão (2), segundo KENDEL (1980).

$$V = \sqrt{\chi^2 / N(k-1)} \quad (2)$$

onde:

N= é a frequência total das classes;  
k= número de linhas e colunas.

#### 4.4.4- Divergência Transformada

A fim de se avaliar o grau de separabilidade espectral entre as classes é determinada a divergência transformada. A divergência é uma medida de separabilidade de um par de distribuições de probabilidade. As equações 1 e 2 determinam a divergência transformada que é baseada na matriz de covariância das amostras coletadas para cada classe ao nível de pixel (RICHARDS & JIA, 1998).

$$Dij = 1 / 2tr(ci - cj)(ci^{-1} - cj^{-1}) + 1 / 2tr(ci^{-1} - cj^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T \quad (1)$$

onde:

Dij- divergência para um par de distribuição (assinaturas);  
Tr- somatório da diagonal principal;  
ci- matriz de covariância para assinatura i;  
cj- matriz de covariância para assinatura j;  
T- Matriz transposta.

A divergência transformada é dada pela equação 2.

$$TDij = 2000(1 - \exp^{(-Dij/8)}) \quad (2)$$

De acordo com JENSEN (1996) a divergência transformada expressa o decréscimo exponencial do peso para o aumento exponencial da distância entre as assinaturas. Os valores da divergência podem variar de 0 a 2000. Como regra geral,  $TDij \geq 1900$  indica que classes podem ser bem separadas; entre  $1700 \leq TDij \leq 1900$  a separação é boa a razoável e  $TDij \leq 1700$  a separação pode ser bem deficitária ou não separável. Os valores da divergência a serem obtidos para alguns pares de classes servirão de base a uma avaliação preliminar de possíveis confusões espectrais na discriminação de classes no ambiente ciliar (item 5.2).

## 5- RESULTADOS E DISCUSSÕES

Este capítulo mostra primeiramente o resultado da interpretação da imagem e chave da fotointerpretação, representando a base do conhecimento. Em seguida, é discutida a classificação da imagem ao nível de pixel, para então, posteriormente avaliar a metodologia proposta no Capítulo 4.

### 5.1- INTERPRETAÇÃO VISUAL DA IMAGEM NOS TRÊS DOMÍNIOS

Realizou-se uma interpretação baseada no domínio da cena, da imagem e dos segmentos. Primeiramente, a imagem foi analisada qualitativamente, observando e identificando feições do terreno e a seguir confrontando com a realidade de campo, através de visita *in loco*. O conhecimento do comportamento espectral de algumas feições como *várzea*, *floresta*, *eucalipto*, *agricultura* e *solo exposto* foram importantes na interpretação no domínio da imagem. Considerando, por exemplo, duas regiões da imagem ocupadas por *solo exposto* (*arado*) e *solo urbano*, ambas também apresentaram respostas espectrais similares em todas as bandas utilizadas, de maneira que a discriminação não foi possível ao nível puramente espectral. No entanto, a separação dessas duas classes pôde ser realizada considerando aspectos de forma. Em geral, *campos* e *arados* possuem uma forma regular, ao contrário de solo urbano mais irregular.

O domínio dos segmentos permitiu numa primeira instância observar forma e tamanho de alguns objetos que a princípio pareciam espectralmente próximos entre si. Pôde ser efetuada uma interpretação visual associando as nuances das formas dos objetos com as feições, como complemento à interpretação espectral da imagem. A Tabela 4 apresenta as feições de interesse na cena e sua respectiva semântica.

TABELA 4- RESULTADO DA INTERPRETAÇÃO NOS TRÊS DOMÍNIOS DA IMAGEM, CENA E SEGMENTOS. COMPOSIÇÃO COLORIDA FALSA COR BANDAS 4, 3, 2

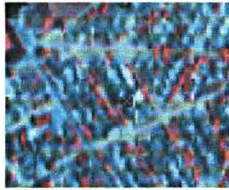

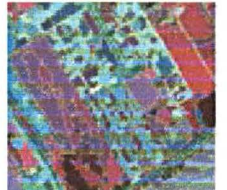
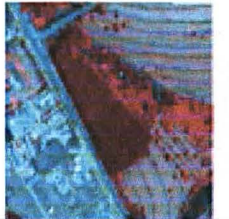
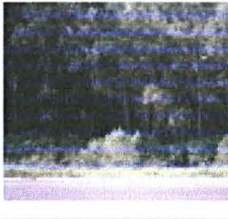
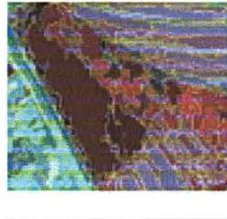
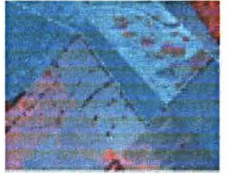

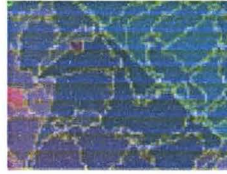
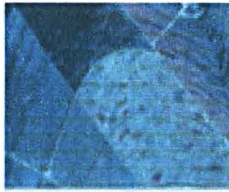


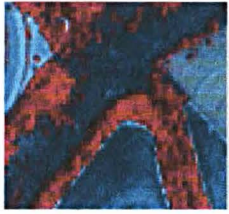

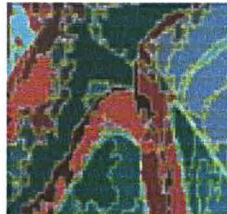

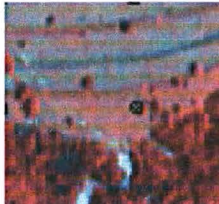
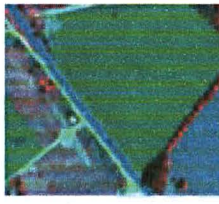
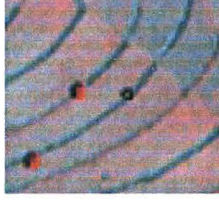
Classe	Descrição Domínio da Imagem <i>Composição em RGB (4, 3, 2)</i>	Domínio da Cena* <i>Fotografia in loco</i>	Descrição domínio dos objetos <i>Composição em RGB (4, 3, 2)</i>
Área Urbana	<p>Textura Rugosa definida.</p> <p>Alta refletância nas bandas do visível</p> 		 <p>Objetos de formas irregulares e pequenos.</p> <p>Assimétricos e pouco compactos</p>
Eucalipto	<p>Alta reflexão na banda do infravermelho</p> <p>Textura fina e forma definida.</p> 		 <p>Objetos pouco assimétricos. e suavizados.</p> <p>Apresenta certo grau de compacidade</p>
Outras culturas	<p>Alta reflexão nas bandas do visível.</p> 		 <p>Objetos de contornos arredondados.</p> <p>Assimetria variável</p>
Cana	<p>Alta reflexão da banda do Infravermelho e vermelho.</p> 		 <p>Objetos de forma irregular, assimétrico</p> <p>Orientação variável.</p>
Várzea	<p>Alta reflexão na banda do infravermelho</p> 		 <p>Objetos alongados, pouco suavizados e assimétricos.</p> <p>Com adjacência a classe rio.</p>



TABELA 4- Continuação

<b>Classe</b>	<b>Descrição Domínio da Imagem</b> <i>Composição em RGB (4, 3, 2)</i>	<b>Domínio da Cena*</b> <i>Fotografia in loco</i>	<b>Descrição domínio dos objetos</b> <i>Composição em RGB (4, 3, 2)</i>
<b>Florestas e mata de galeria</b>	Alta refletância na banda infravermelha.  Textura rugosa definida.		Objetos de tamanhos regulares poucos fractados.  Pouco assimétricos e compactos
<b>Capoeirinha</b>	Boa resposta espectral nas bandas vermelho e infravermelho e textura fina.		Orientação pouco variável, forma alongada. Objetos assimétricos
<b>Solo Exposto</b>	Alta refletância nas bandas do visível.		Padrão horizontal.  Pouco assimétrico.  Forma suavizada
<b>Pasto</b>	Alta reflexão nas bandas do visível		Objetos alongados de padrão uniforme.  Formas pouco suavizadas.

\*descrição das classes: vide item 2.3 página 22.

FONTE: Adaptado LINGNAU et al, 2001

## 5.2- RESULTADOS DA CLASSIFICAÇÃO AO NÍVEL DE PIXEL

Comparou-se o classificador de máxima verossimilhança com o classificador leve baseado em lógica fuzzy proposto por EASTMANN (1997).

### 5.2.1- Máxima Verossimilhança (maxver)

A fim de avaliar o classificador de máxima verossimilhança foram selecionadas amostras para as seguintes classes: *floresta, eucalipto, várzea, solo exposto, pastagem, agricultura e capoeirinha*. A partir destas amostras foram obtidas as médias e matrizes variâncias-covariância para as classes envolvidas. Utilizando o algoritmo da máxima verossimilhança, foram determinadas as funções densidade de probabilidade de acordo com a expressão do Teorema de Bayes abaixo:

$$p(\omega_i|x) = (p(x|\omega_i) * p(\omega_i)) / p(x) \text{ e } p(x|\omega_i) = (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp\{-1/2(x-\mu_i)^t \Sigma_i (x-\mu_i)\} \quad (1)$$

onde:

N é o número de classes,

$p(x|\omega)$  denota a probabilidade de um pixel x pertencer a uma classe  $\omega$ ,

$p(\omega_i)$  descreve a probabilidade *a priori* (no caso igual a um);

$p(x)$  a probabilidade do pixel ocorrer na imagem

$(\mu)$  é a média e  $(\Sigma_i)$  matriz variância-covariância

O resultado da classificação foi deficitário para algumas classes tais como *várzea, agricultura e pastagem*, que não foram adequadamente discriminadas, por possuírem respostas espectrais muito próximas. Foi considerada apenas a característica espectral para os pixels. Houve certa dificuldade em se discriminar algumas classes considerando unicamente valores de níveis de cinza.

A determinação da divergência (item 4.4.4) transformada indicou que as classes: *Mata de Galeria e Floresta (não ciliar)* apresentaram respostas espectrais tão similares que não podem ser distinguíveis no domínio espectral (Tabela 5). Ao nível de pixel estas classes tiveram que ser unidas em uma única classe mais geral- *Floresta*. O mesmo ocorreu com a classe *solo urbano e solo exposto*. Os demais pares de classes não apresentadas na Tabela 5 puderam ser separáveis espectralmente, pois apresentaram valores superiores a 1900.

TABELA 5- DIVERGÊNCIA TRANSFORMADA PARA AS CLASSES MENOS DISTINGUÍVEIS.

PARES DE CLASSES	TDIJ	SEPARABILIDADE
<i>Eucalipto/Floresta(Ciliar)</i>	1940	Boa
<i>Eucalipto/Mata de Galeria</i>	1900	Boa
<i>Mata de Galeria/ Floresta</i>	0900	Não separável
<i>Mata de Galeria/Várzea</i>	1730	Separação Razoável
<i>Solo urbano/Solo Exposto</i>	1300	Não separável
<i>Várzea/Agricultura</i>	1800	Separação razoável

Em imagens de alta resolução o problema de erros na classificação devido a pixels mistos diminuiu, contudo a variabilidade espectral entre pixels é bem acentuada. Como consequência a classificação por máxima verossimilhança pode produzir muitas classes, porém não bem definidas, e com ruídos, uma vez que este método baseia-se tão somente nos parâmetros espectrais do dado. Desta forma, fica inviabilizada o potencial discriminatório para as classes do ambiente ciliar da imagem. O resultado da classificação pôde ser observado na Figura 21. As maiores confusões entre as classes ocorrem de acordo com a divergência transformada da Tabela 5. Muitas áreas de *agricultura* foram classificadas como *várzea* e algumas áreas de *Floresta* foram classificadas como *Eucalipto*. No ambiente ciliar foi impossível separar *Floresta* de *Mata de Galeria*, o que levou a uma generalização para uma só classe denominada *Florestas*.



### 5.2.2- Classificação fuzzy

O método de classificação fuzzy utilizado foi o proposto por WANG (1990a) e implementado por EASTMANN (1997), apresentado no item 4.3.1. A amostragem Fuzzy (áreas de treinamento) para classificação supervisionada difere da convencional, que de forma geral foi realizada em áreas com pouca variabilidade espectral ou homogênea. Na amostragem fuzzy a tendência de homogeneidade foi menos importante e uma área de treinamento pôde ser usada para gerar parâmetros para mais de uma classe. Neste trabalho as funções de pertinência para cada classe foram baseadas utilizando as funções densidade de probabilidade, considerando a média e a matriz de covariância oriundas da amostragem fuzzy.

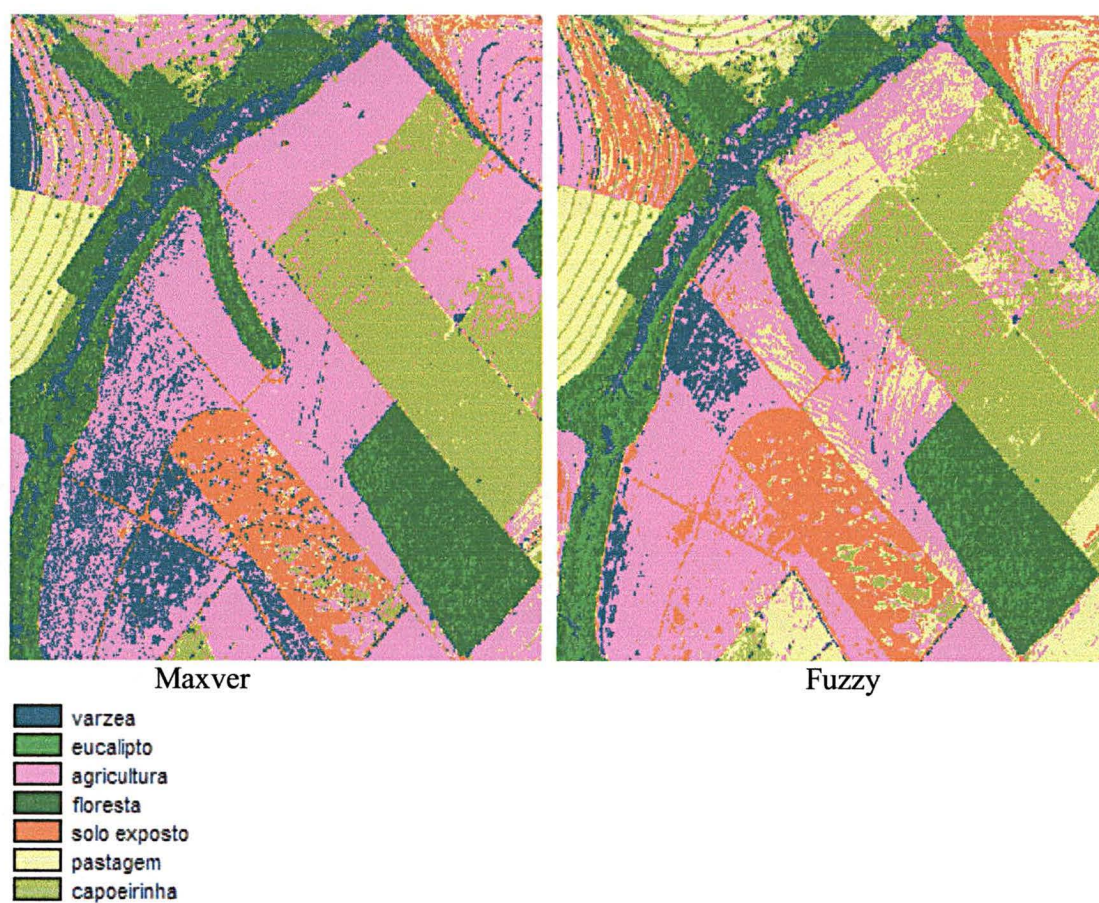
O resultado da classificação foi uma imagem onde cada pixel é associado à classe com maior grau de pertinência denominado “desfuzzificação”. Este procedimento permitiu também avaliar a ambigüidade da classificação baseada nas incertezas, ou seja, graus de pertinência próximos entre si. Por conseguinte, classes com respostas espectrais próximas entre si, tais como *várzea*, *agricultura* e *pastagem*, apresentaram incertezas ou pertinências similares.

Com o intuito de se verificar o grau de concordância da imagem classificada foi determinado o coeficiente de concordância *Tau* (ANEXO 2). Foi também calculado *Tau* para imagem classificada no item anterior (Tabela 6). A acurácia total para a imagem fuzzy foi superior à imagem máxima verossimilhança, confirmando o observado visualmente na imagem.. O índice de concordância Cramer’s V entre ambas foi  $\tau_{max/fuz} = 0,54$ . Isto significa um certo grau de divergência entre as duas imagens da Figura 21.

TABELA 6- GRAU DE CONCORDÂNCIA  $\tau$  DAS CLASSIFICAÇÕES AO NÍVEL DE PIXEL.

CLASSES	$\tau$ (FUZZY)	$\tau$ (MAXVER)
<i>Eucalipto</i>	0,40	0,29
<i>Floresta</i>	0,58	0,54
<i>Várzea</i>	0,45	0,33
<i>Pastagem</i>	0,45	0,30
<i>Solo Exposto</i>	0,58	0,50

FIGURA 21- COMPARAÇÃO DA CLASSIFICAÇÃO FUZZY E MAXVER DE UMA PARTE DA IMAGEM




Observou-se em ambos os métodos de classificação um baixo grau de concordância (inferior a 0,50) com a verdade de campo (Tabela 6). Para a classe de *eucalipto* houve somente uma concordância de 40 %, considerando a classificação

fuzzy. Todavia, método fuzzy mostrou-se o mais adequado de acordo com as seguintes ponderações:

- a)- A representação fuzzy da informação geográfica representada numa imagem orbital de grande variabilidade espectral pareceu ser mais adequada, pois, condições intermediárias entre padrões puderam ser descritas por meio de graus de pertinência (Figura 21);
- b)- Os graus de incerteza da classificação puderam ser mais bem avaliados através de baixos graus de pertinência. Na Figura 22 à esquerda, observam-se os pixels com graus de incerteza, próximo a 1 em amarelo. Na imagem à direita da Figura 22, observa-se a alta variabilidade espectral na composição colorida (bandas 4, 3, 2) .

FIGURA 22- GRAUS DE INCERTEZA PARA A CLASSE: FLORESTA



- c)- A análise de incertezas ou ambigüidades induz à utilização de outras fontes de dados complementares e leva à criação de novas funções fuzzy a fim de melhorar a acurácia da classificação. Pois neste caso, só o dado espectral não foi suficiente para discriminar algumas classes do ambiente ciliar (Tabela 5).

- d)- A lógica fuzzy em nível de pixel se apresentou como um ponto de partida na classificação digital de imagem de alta resolução, pois explicita o grau de

complexidade de categorização da imagem devido ao alto grau de variabilidade espectral e radiométrica dos pixels.

Esse estudo preliminar de classificação supervisionada fuzzy apresentou-se como uma forma alternativa da interpretação da imagem, pois informação sobre o grau de associação de um pixel a determinada categoria tornou-se disponível. Percebeu-se que este tipo de análise serve como subsídio à introdução do conhecimento na classificação digital.

### 5.3- SEGMENTAÇÃO

A segmentação da imagem foi realizada através do método de multi-resolução descrito no item 4.1. A imagem foi segmentada em três diferentes níveis, que permitiram extrair objetos da imagem em diferentes definições. A segmentação ao nível de alta resolução (estruturas finas), possibilitou a extração de objetos primitivos (pequenos) e significativos para a classificação. A partir deste nível mais detalhado objetos maiores ou regiões puderam ser gerados por meio de fusão (item 4.1). O processo de criação de diferentes níveis hierárquicos de objetos (superobjetos e subobjetos) foi baseado em critérios de semelhança e de peso atribuído ao dado multiespectral. A Tabela 7 mostra os parâmetros utilizados no processo de multi- resolução.

TABELA 7- PARÂMETROS UTILIZADOS NA SEGMENTAÇÃO


<b>Bandas:</b>	w.b <sub>i</sub> ; onde w= peso, w=1 para as quatro bandas i.
<b>Fator Escala:</b>	Nível 1= 20; Nível 2=40, Nível=80
<b>Fator Espectral (cor) e Forma:</b>	Fe= 0,7; Ff= 0,3; Fe= fator espectral; Ff= fator de forma.

Como já citado no Capítulo 4, o parâmetro da escala ou resolução de segmentação determinou o tamanho médio do objeto da imagem, permitindo uma mudança na heterogeneidade durante todo processo de segmentação. A Tabela 7 mostra as diferentes resoluções adotadas



nos diferentes níveis. O fator escala demonstrou ser um valor abstrato dependendo do escopo do trabalho e do tipo de imagem. Neste caso o fator escala foi definido a partir da complexidade dos alvos e seu poder discriminatório avaliados a partir da interpretação no domínio da imagem (Tabela 4). Iniciou-se com o menor fator de escala menor possível (10), que serviu como base às outras segmentações. O fator escala menor permitiu que nos níveis subsequentes informações sobre textura pudessem ser obtidas. O resultado são três imagens segmentadas com diferentes graus de detalhes possuindo parentesco ou hierarquia. Os objetos adquirem relações, uma vez que, superobjetos são formados pelo agrupamento de subobjetos (Figura 23).

FIGURA 23- IMAGENS SEGMENTADAS COM DIFERENTES FATORES DE ESCALA (20, 40, 80).



O conhecimento adquirido, nos diferentes domínios de interpretação, permitiu a consecução de uma estrutura semântica. As características dos objetos possibilitaram limitar o conhecimento adquirido no domínio da imagem, ou seja- o limiar de especialização ou generalização. A fim de introduzir a rede semântica de forma eficiente dentro da hierarquia multi-resolução, realizou-se um estudo visando esclarecer quais descritores seriam mais apropriados para distinguir os objetos.

Com o intuito de facilitar a interpretação, as classes foram divididas em dois grandes grupos semânticos mostrados na Figura 16 (item 4.2.3.3- Formalização da Hierarquia) baseada na descrição do conhecimento.

De acordo com estudos preliminares de classificação por regras fuzzy ao nível de pixels (item anterior) e da análise das amostras coletadas para classificação máxima verossimilhança (item 5.2.1, Tabela 5), detectaram-se níveis de incertezas na discriminação das seguintes classes listadas na Tabela 8.

**TABELA 8- RELAÇÕES DE INCERTEZA DAS CLASSES BASEADAS NA CLASSIFICAÇÃO FUZZY (PIXEL) E DIVERGÊNCIA TRANSFORMADA.**

<b>CLASSES</b>	<b>RESULTADO DA CLASSIFICAÇÃO FUZZY (PIXEL)</b>	<b>INCERTEZA</b>
<b>Várzea e Agricultura</b>	Resposta espectral próxima devido a solo úmido em corte raso de cana na banda 4. Pouco Separável.	Alta
<b>Várzea e Mata de Galeria</b>	Resposta espectral próxima em áreas menos úmidas na banda 4. Separável.	Média
<b>Solo Exposto e Solo urbano</b>	Resposta espectral muito próxima para todas as bandas. Dificil distinção	Alta
<b>Mata de Galeria e Floresta (Ambiente não Ciliar))</b>	Resposta espectral idêntica para todas as bandas. Não Separável.	Alta
<b>Eucalipto e Floresta</b>	Resposta espectral diversa para banda 4. Separável.	Média

No domínio dos objetos pôde-se avaliar a variabilidade das categorias por amostragem, analisando as variabilidades de forma e textura. Para cada classe se amostrou um grupo de objetos. Baseado nos descritores disponíveis (espectral, forma e textura), iniciou-se um processo de associação entre a variabilidade dos valores dos descritores e a variabilidade dos objetos do mundo real, em outras palavras, objetivou-se responder a questão : “Quais descritores prestam-se para associar determinado objeto à determinada classe”? O resultado da análise foi a chave da interpretação no domínio dos objetos (ver Tabela 4).

De acordo com o exposto acima, poucas classes puderam ser distinguidas apenas por parâmetros espectrais, logo se lançou mão de outras fontes de dados como parâmetros de forma, textura e relações com subobjetos, que serão descritas a seguir.

### 5.3.1- Discriminação das Classes

#### 5.3.1.1- *Várzea e agricultura*

Sobre a imagem segmentada foram amostrados alguns objetos que representaram *várzea* e *agricultura*, as quais apresentaram confusão na classificação ao nível pixel devido a proximidade espectral entre ambas as classes- principalmente em áreas irrigadas ou com alto grau de umidade (Tabela 8). A Figura 24 apresenta na imagem segmentada amostras para ambas as classes a fim de se obter os conjuntos fuzzy. Dentre os vários descritores testados, a melhor discriminação ocorreu no descritor média da banda 4 e assimetria dos objetos.

A princípio a forma alongada da *várzea* em azul difere da forma de *agricultura* em amarelo. Descritores de assimetria e comprimento puderam ser considerados também como parâmetros discriminatórios.


FIGURA 24- AS AMOSTRAS EM AMARELO PARA AGRICULTURA E EM VERMELHO PARA VÁRZEA



Observa-se na figura 25 a distribuição das amostras de *várzea* (azul) e *agricultura* (preto) para os conjuntos fuzzy relacionados aos descritores de forma (assimetria) e espectral (média banda 4). Simulando uma classificação das duas classes baseadas nos descritores acima, foi possível discriminar algumas regiões de *várzea* e *agricultura*. Houve, contudo,

objetos que não puderam ser classificados, pois se situavam fora da área de abrangência das funções de pertinência. Desta forma, ampliando o intervalo de valores das funções de pertinência se observou um menor número de objetos não classificados. Não obstante existiram erros de classificação, haja vista a proximidade dos parâmetros espectrais e de forma para as duas categorias, de acordo com os gráficos da figura 25. Porém tais erros puderam ser mitigados através da rede semântica proposta na figura 16, uma vez que as classes ficaram atreladas a diferentes grupos semânticos, excluindo assim a possibilidade de confusão.

FIGURA 25- DESCRITORES DE ASSIMETRIA E MÉDIA ESPECTRAL PARA BANDA INFRAVERMELHA, PARA AS CLASSES DE AGRICULTURA (EM PRETO) E VÁRZEA (EM AZUL)




#### 5.3.1.2- Várzea e mata de galeria

A separação de classes dentro de um mesmo grupo semântico depende de descritores de relações de contexto. O contexto da *várzea* e da *mata de galeria* está vinculado à existência do vetor *rio*, inserido como informação temática, e as duas classes fazem parte da



classe ambiente ciliar (*várzea* + *mata de galeria parte\_de ambiente ciliar*). Com a existência (*existence\_of*) da classe ou vetor *rio* foi possível delinear a classe *ambiente ciliar* e a partir desta separar espectralmente *várzea* e *mata de galeria*. A *várzea* existe ao longo do rio em áreas mais baixas e, por outro lado, em áreas menos inundáveis ocorre a *mata de galeria* com vegetação arbórea (capítulo 2). As classes possuem características espectrais distintas (Figura 26). Assim, a banda do infravermelho foi suficiente para separar estas duas subclasses. A Figura 26 mostra a classe de *várzea* em verde escuro ao longo do rio e a *mata de galeria* em vermelho dentro do contexto de ambiente ciliar.

FIGURA 26- RELAÇÕES DE CONTEXTO, RIO, MATA DE GALERIA E VÁRZEA NO DOMÍNIO DA IMAGEM




É importante salientar que estas duas classes foram separadas espectralmente por terem herdado propriedades da classe superior *Ambiente Ciliar*. A rede semântica potencializou de certa forma a informação espectral.

### 5.3.1.3- *Solo rbano e solo exposto*

Nestas duas subclasses do grupo semântico *outros* os descritores de forma assumiram um papel importante. Confirmou-se o constatado por HOFFMAN (2002b) que salienta a aplicabilidade do uso de parâmetros de forma e textura para extração de feições do ambiente urbano. A média do tamanho dos subobjetos e a sua diferença média espectral atua como

padrão de textura. Em adição, para distinguir construções (componentes de solo urbano) de assimetria dos subobjetos foi interessante, pois descreveu o grau de alongamento do objeto. Outro critério observado e baseado na forma foi densidade que descreve a compactidade dos objetos. As áreas de *solo exposto* (solo preparado para plantio) em geral são mais compactas próximas a quadrados, trapézios e retângulos (Figura 27 A), enquanto *solo urbano* possui forma totalmente irregular mais assimétrica (Figura 27 B) . A Figura 27 mostra para *solo exposto* em azul e *urbano* em preto os valores do descritor textura baseado em valores médios de assimetria ao nível de subobjetos.

FIGURA 27- GRÁFICO DE TEXTURA. BASEADO NOS VALORES MÉDIOS DE ASSIMETRIA DOS SUBOBJETOS (NO EIXO X).



#### 5.4- CLASSIFICAÇÃO

A interpretação dos objetos oriundos da segmentação foi bastante útil no processo de generalização, abstração e estruturação da semântica. O processo de interpretação da imagem com vistas à classificação passou pelas seguintes etapas:

- 1- Estruturação da base do conhecimento;
- 2- Análise da forma dos objetos no domínio dos segmentos;

- 3- Características dos descritores dos objetos e suas propriedades discriminatórias;
- 4- Inserção do conhecimento por meio de regras fuzzy e relações de contexto entre as regiões.

#### 5.4.1- Parâmetros descritores

A Tabela 9 apresenta os descritores utilizados para separar as diferentes classes proposta na Figura 16. Os descritores foram testados utilizando a estrutura hierárquica e o procedimento de especialização da cena (sentido crescente de detalhes a partir de diferentes níveis).

Observou-se que a utilização de muitos descritores para uma só classe (ex.: espectral, forma , textura e contexto) podem aumentar o grau de complexidade da classificação, tendo em vista a dificuldade observada em determinar os valores dos limites dos conjuntos fuzzy. A fim de melhorar o desempenho do processo estratificação temática, adotou-se um número menor possível de descritores.

Com o objetivo de verificar a utilidade dos descritores apresentado no capítulo anterior, (Tabelas 2 e 3, capítulo 4), foram selecionadas várias amostras para diferentes classes e analisada a eficiência discriminatória de cada descritor (Tabela 9).

Foi observado na Tabela 9 que parâmetros de contexto foram fundamentais para a extração da classe *Ambiente Ciliar* e *Ambiente não Ciliar*. Desta forma foi possível separar classes espectralmente próximas entre si, tais como: *Várzea de Agricultura (cana e outras culturas)*; *Várzea de Mata de Galeria*; *Mata de Galeria de Floresta*. Estas classes não foram bem discriminadas pela classificação ao nível de pixel (item 5.1)


TABELA 9- RELAÇÃO SEMÂNTICA ENTRE OBJETOS E DESCRITORES

NIVEL 3 SUPEROBJETOS, Resolução 80	
Classes	Amostragem ao nível de segmentos
<ul style="list-style-type: none"><li>Floresta (vegetação)</li></ul>	Descritores: Média banda 4, infravermelho e Banda 3
<ul style="list-style-type: none"><li>Outros (não floresta)</li></ul>	
NIVEL 2 SUPEROBJETOS, Resolução 40	
Classes	Amostra a nível de segmentos
Grupo Floresta	<b>Herança das características da superclasse 3 (vegetação)</b> <b>Descritores:</b> <b>Contexto: <i>Existência</i> de classe Rio</b>  Espectral: Média da banda 4 Espectral: Média banda 3, Raio e media banda 4, infravermelho. Capoeirinha negação a <i>Existência</i> de Floresta e Eucalipto.
<ul style="list-style-type: none"><li>Ambiente Ciliar</li><li>Ambiente não Ciliar<ul style="list-style-type: none"><li>- Floresta</li><li>- Eucalipto</li><li>-Capoeirinha</li></ul></li></ul>	
Grupo Outros	<b>Herança das características da superclasse do nível 3(outros)</b> <b>Descritores:</b>  Espectral: Razão , média da banda 4, infravermelho; Razão banda 3. Espectral: Média da Banda 4; Pastagem negação da <i>Existência</i> de cana e outras culturas
<ul style="list-style-type: none"><li>Outros</li><li>Agricultura<ul style="list-style-type: none"><li>Cana</li><li>Outras culturas</li><li>Pastagem</li></ul></li></ul>	
NIVEL 1 SUBOBJETOS, Resolução 20	
Classes	Amostragem ao nível de segmentos
Ambiente Ciliar	Herança níveis 1 e 2.
<ul style="list-style-type: none"><li>Várzea</li><li>Mata de Galeria</li></ul>	Herança de contexto da classe Ambiente Ciliar. Espectral: Média Banda 4 e Razão da Banda 4.
Outros	Herança nível 2
<ul style="list-style-type: none"><li>Agricultura</li><li>Outros<ul style="list-style-type: none"><li>Solo urbano</li><li>Solo exposto</li></ul></li></ul>	Herança Cana, outras culturas, pastagem  Textura- Relação entre subobjetos Forma: Assimetria e Densidade

#### 5.4.2- Métodos de Classificação baseada em objeto

Um dado segmento foi classificado utilizando as funções de pertinência definidas previamente (signoidal, J-shaped, linear e ajustável), a estas funções foram atribuídos os valores limites baseados em parâmetros específicos. Para algumas classes, mais de uma função fuzzy foram utilizadas, portanto a associação de diferentes descritores. A Figura 28 mostra um exemplo dos valores mínimos e máximos de um conjunto fuzzy considerando o parâmetro densidade (forma) para a classe *solo urbano* (ANEXO 4). Analogamente, este procedimento é repetido para as classes do ambiente ciliar de acordo com a Tabela 9.

FIGURA 28- FUNÇÃO DE PERTINÊNCIA FUZZY BASEADO EM VALORES DE DENSIDADE (FORMA)



A combinação de diferentes conjuntos fuzzy baseados em diferentes descritores foram utilizados para as classes *Solo urbano*; *solo exposto*; *cana*; *outras culturas*. Considerando dois conjuntos fuzzy  $\text{Min}(\mu_A(x); \mu_B(x))$  foi empregado o valor mínimo (intersecção), item 4.3.2. Procurando comparar as diversas formas de classificação por meio de regras fuzzy e avaliar o modelo semântico proposto, classificou-se a imagem de três diferentes formas: (a) rede semântica com níveis de especialização apoiada na segmentação por multi-resolução, no contexto vegetação ; (b) a mesma forma considerando outro contexto baseado na análise de outro especialista; (c) classificação seletiva considerando apenas um nível de segmentação.

#### 5.4.2.1- Classificação baseada na Rede Semântica

De acordo com a interpretação da imagem e da análise da imagem segmentada, adotou-se o método de especialização. Iniciou-se com uma visão genérica da cena, ao nível de superobjetos e as classes foram sendo subdivididas de acordo com os diferentes níveis de segmentação, até alcançar a especialização esperada.

O objetivo de se ter criado diferentes níveis de segmentação foi estabelecer relações entre objetos e subobjetos, permitindo estruturar a hierarquia de classes. Contudo, a associação de cada objeto à determinada categoria dependeu das regras fuzzy baseadas nos descritores espaciais citadas. A vantagem da utilização da rede semântica foi que o processo de especialização, em termos de níveis hierárquicos, possibilitou uma separação natural das classes, conduzindo a uma dependência menor de descritores.

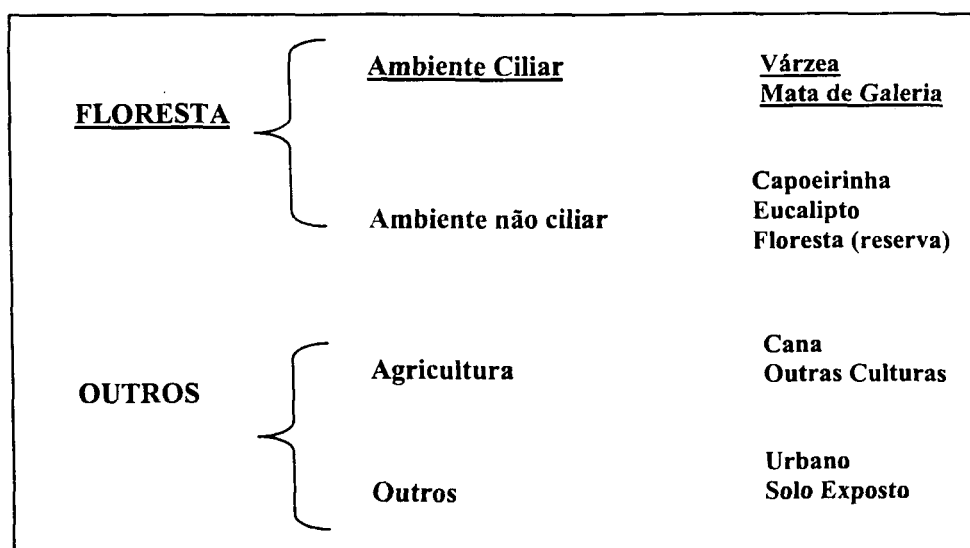
A Tabela 10 mostra sobre a imagem original as amostras dos objetos associados à *floresta* e *outros* para os três níveis hierárquicos. A variação do valor dos parâmetros foi representada no eixo x e o grau de pertinência (0,1) no eixo y (Figura 28). No nível 3 (mais generalizado) a função de pertinência selecionada baseou-se em parâmetros espectrais que permitiram a separação de dois primeiros grupos semânticos (*Floresta* e *outros*, Figura 29).

Observa-se na Tabela 10 dois grandes grupos semânticos *Floresta* e *Outros*, de acordo com o esquema proposto na Figura 29. A classe *Floresta* no nível 3, mais geral referiu-se a todos os tipos de floresta presente na cena, tais como: *várzea*, *mata de galeria*, *eucalipto* e *floresta* (reservas de floresta secundária fora do ambiente ciliar). A super classe *outros* foi a negação da classe floresta ou não floresta. Esta classe é composta por *solo exposto*, *solo urbano*, *agricultura*, *pastagem*, etc.

Em um nível mais detalhado, objetos menores (ex.: nível 2, Tabela 10), pôde-se dividir as super classes em classes menores. No nível 2 a *Floresta* foi subdividida em *Ambiente Ciliar* e

*Ambiente não ciliar*, e observou-se que não existiu qualquer mistura com a classe *Outros*, ou seja, uma vez que os grupos foram separados ao nível mais genérico, esta separação foi mantida nos níveis subseqüentes. As subclasses formaram na verdade subconjuntos das superclasses em um nível mais genérico.

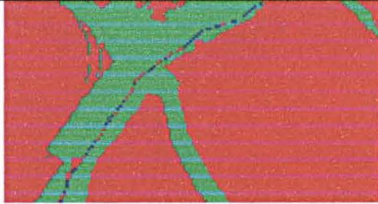
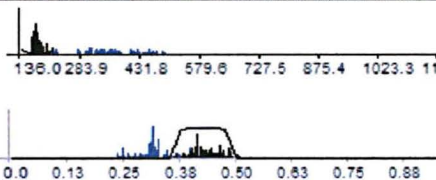
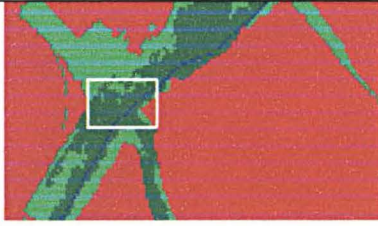
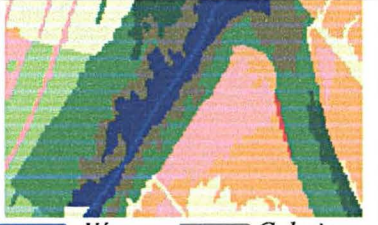
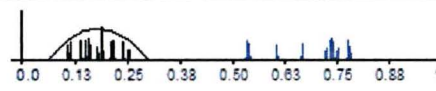
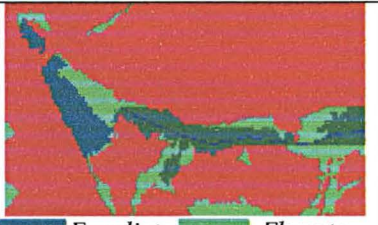
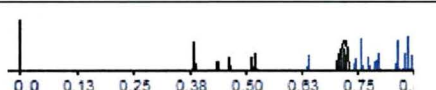
FIGURA 29- GRUPOS SEMÂNTICOS



É oportuno salientar que o resultado obtido esteve de acordo com os descritores apresentados na Tabela 9. Observou-se inicialmente que classes como *várzea* e *agricultura* foram de difícil distinção no espaço espectral, não obstante no modelo semântico proposto ter sido possível separá-las, uma vez que estas pertenciam a grupos semânticos distintos.



TABELA 10- CLASSIFICAÇÃO POR ESPECIALIZAÇÃO: BASEADA EM HIERARQUIA E REGRAS FUZZY PARA O AMBIENTE CILIAR

Níveis	CLASSES	IMAGEM	DISCRIMINAÇÃO FUNÇÕES*
Nível 3	<p>Floresta e Outros</p> <p><i>Herança: sem</i></p>	 <p>Vegetação    Outros</p>	 <p>Vegetação    Outros</p> <p>Funções Fuzzy Bandas 3 e Razão da Banda 4</p>
Nível 2	<p>Ambiente Ciliar e Ambiente não Ciliar</p> <p><i>Herança : floresta</i></p>	 <p>Ciliar    Não Ciliar</p>	<p>Existência da Classe Rio oriunda do arquivo vetorial.</p>
Nível 2	<p>Várzea e Mata de Galeria</p> <p><i>Herança: Ambiente Ciliar (nível 2)</i></p>	 <p>Várzea    Galeria</p>	 <p>Várzea    Mata de Galeria</p> <p>Razão Banda 4</p>
Nível 2	<p>Eucalipto e Floresta</p> <p><i>Herança: Ambiente não ciliar</i></p>	 <p>Eucalipto    Floresta</p>	 <p>Eucalipto    Floresta</p> <p>Razão Banda 4</p>

\* ver Tabelas 2 e 3 , item 4.3.3

Certificou-se, de acordo com a Tabela 10, que a própria hierarquia serviu como fator discriminante (ANEXO 4).

A estrutura de hierarquia e especialização puderam gerar classes cada vez mais específicas que muitas vezes não são importantes ao objetivo do mapa temático. O potencial



de discriminação foi limitado ao nível mais detalhado, segundo o escopo do mapa temático e conseqüentemente de acordo com a rede semântica proposta.

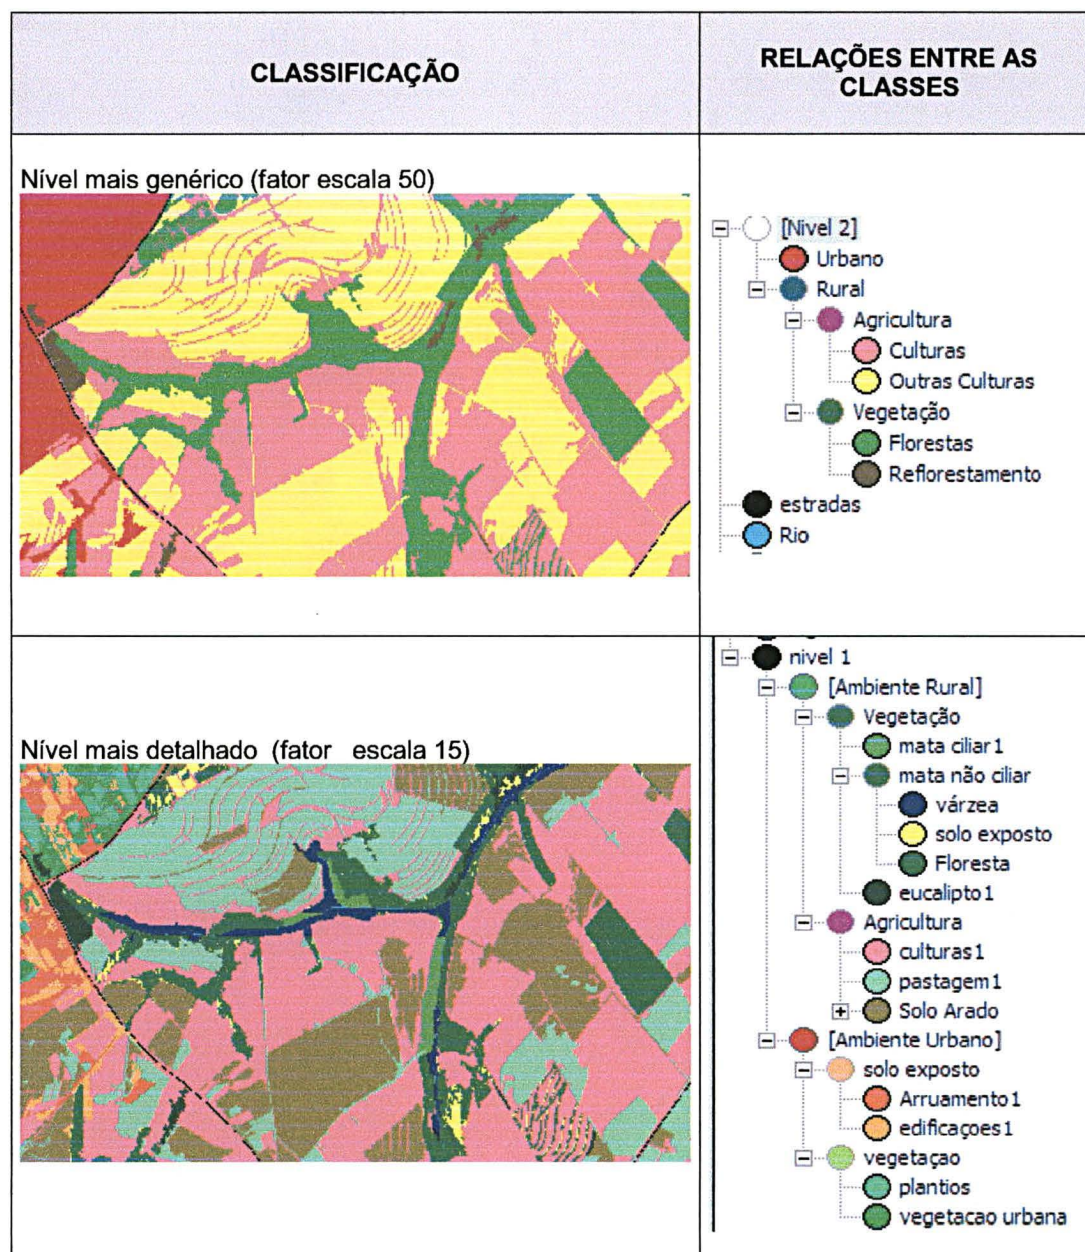
O resultado desta classificação foi adotado como o mais adequado, e serviu de base para comparação de outras metodologias tanto ao nível de pixel quanto ao nível de objeto. A classificação de toda área de estudo é apresentada no ANEXO 5.

#### ***5.4.2.2- Classificação baseada no contexto de outro especialista (cognição assimétrica)***

Diferentes interpretações da cena baseadas no cógnito geram diferentes classificações que podem se distanciar da realidade. Apesar de toda a classificação ser uma generalização da realidade, deve-se almejar determinado grau de correspondência com o mundo real.

A Figura 30, abaixo, mostra uma classificação realizada por outro especialista sobre uma outra perspectiva. Para este especialista foi necessário segmentar a imagem em quatro diferentes níveis. As classes do nível mais genérico ou superclasses foram *urbano*, *rural*. De maneira análoga ao efetuado no item anterior as subclasses foram oriundas destes dois grandes grupos. Desta forma, subclasses como *mata de galeria*, *eucalipto* herdaram propriedades da superclasse *rural* (negação de *urbano*). As classes de acordo com a Figura 30 tiveram grau de parentesco bem diferentes da classificação anterior (item 5.5.2). Novas classes surgiram, tais como *vegetação urbana*, *construções* e *estradas*. Observou-se, contudo, que as classes tais como *eucalipto*, *várzea*, *floresta (não ciliar)*, coincidiram de certa forma com a classificação do item anterior.

FIGURA 30- CLASSIFICAÇÃO BASEADA NO CONTEXTO URBANO E RURAL .



Na estrutura semântica proposta, atentou-se para o enfoque de classes referentes ao grupo semântico *urbano*, onde se puderam detectar por meio de descritores espectrais, de forma e textura, as classes de *arruamento*, *edificações* e *vegetação urbana*. A classe *solo exposto* aparece tanto como subclasse de *mata não ciliar* quanto de *ambiente urbano* (Figura

30), pertencendo a mesma classe a dois contextos distintos, a primeira com significado de *desmatamento* (clareiras e voçorocas) e a outra como *solo descoberto* em áreas urbanas. No caso da classificação do item anterior estas classes se referiram a um único contexto.

Diferentes pontos de vista podem gerar diferentes resultados, uma vez que a classificação hierárquica é apoiada no conhecimento e no contexto. Isto reforça o descrito no capítulo anterior que se refere à importância do usuário em pré-definir com rigor o objetivo da classificação e ainda ressaltar que categorias são mais importantes. A percepção do espaço e as relações lógicas entre os objetos e seus atributos é a base para a concepção da estrutura semântica, que por fim permite a eficiência do processo.

#### 5.4.2.3 - Classificação Seletiva

Outra forma de classificação testada por meio de regras fuzzy foi a estratégia seletiva, baseada em segmentação única, ou seja, a um único nível. O método consiste em detectar as classes de interesse baseado simplesmente nos descritores. Neste caso, não existiram relações de superobjetos e subobjetos em diferentes níveis de segmentação. As classes foram subdivididas, em um mesmo nível (Figura 31).

Em contraste com estratégia de especialização, na estratégia seletiva fez-se uma tentativa para detectar classes de interesse descrevendo-as diretamente, de forma tão exata quanto possível. Conseqüentemente o especialista tem que estar ciente de propriedades disjuntivas tanto em relação aos descritores quanto ao conhecimento *a priori*.

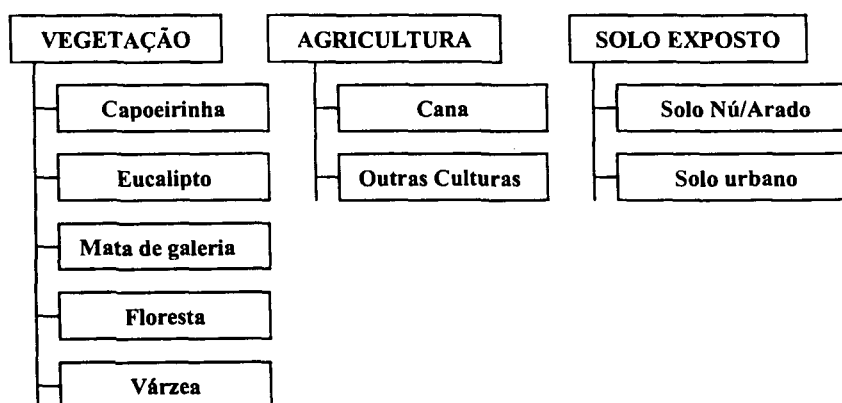
Na comparação com a estratégia de especialização a hierarquia da classe de uma classificação seletiva apresentou-se mais compacta, pois não houve hierarquia entre níveis (Figura 31). Por outro lado a complexidade das descrições das classes foi maior, considerando

que mais parâmetros foram necessários. Neste modelo informação a adicional de contexto foi fundamental.

Uma vez que não existiram relações entre superobjetos e subobjetos, fez-se mister uma análise mais minuciosa dos parâmetros a serem inseridos nas funções de pertinência. Para discriminar *várzea* de *mata de galeria*, utilizou-se o modelo digital do terreno como dado suplementar, que na classificação do item anterior não foi necessário. Também devido à ausência de grupo semântico multi-resolução não foi possível discriminar a classe de *mata de galeria*, e houve ainda confusão na discriminação das classes de *Ambiente ciliar* e *Floresta*. Espectralmente próximas entre si estas classes foram separadas em algumas áreas da imagem por descritores de forma.

Vários descritores fuzzy foram utilizados formando um grupo de regras fuzzy. Como já comentado anteriormente, à medida que mais regras fuzzy tornaram-se necessárias, mais complexo se tornou a determinação dos valores limítrofes das funções de pertinência. A ausência de relações entre os objetos em diferentes níveis reduziu a discriminação das classes. Sem a estrutura de uma semântica previamente definida, tornou-se árduo o processo de classificação.

FIGURA 31- ESTRUTURA SEMÂNTICA COM AUSÊNCIA DE NÍVEIS HIERÁRQUICOS



Observou-se que a estratégia seletiva apresentada- baseada em um único nível de objetos- mostrou-se menos eficaz que ambas classificações baseadas em contexto hierárquico.

Uma das grandes vantagens de se inserir a hierarquia, de acordo com item 5.4.2.1, foi a possibilidade de se categorizar objetos em grupos semânticos estruturados que permitiram mais independência de descritores.

## 5.6-TESTES DE ACURÁCIA

As técnicas de classificação supervisionada apresentadas baseadas em objeto, atingiram bons resultados. Entretanto, todo o processo de classificação está sujeito a erros dos mais diversos tipos e fontes. Tendo em vista que os objetos são oriundos de segmentação, diferentes critérios de semelhança podem gerar diferentes limites entre objetos.

A avaliação da acurácia dos dados extraídos das imagens está diretamente relacionada com a confiabilidade temática do mapeamento. Entende-se que a avaliação de diferentes métodos de classificação deva estar embasada na qualidade do dado temático resultante.

### 5.6.1- Determinação do potencial de discriminação

Observou-se que as classificações baseadas em segmentação multi-resolução apresentaram um incremento temático maior se comparado à segmentação a um único nível. Isto se deveu em virtude da especialização da cena e da inserção do contexto. A Tabela 11 ainda relaciona o número de classes com a acurácia. A efetivação de uma classe dependeu do grau de confiabilidade da mesma em relação à interpretação da imagem.

TABELA 11- POTENCIAL DE DISCRIMINAÇÃO PARA AS DIFERENTES CLASSIFICAÇÕES TESTADAS.

CLASSIFICAÇÃO	NÚMERO DE CLASSES	ACURÁCIA*
<i>Rede Semântica</i>	12	boa
<i>Mudança de contexto</i>	12	boa
<i>Seletivo</i>	09	razoável
<i>Fuzzy pixel</i>	10	baixa

\* ver índices de acurácia Tabela 12

### 5.6.2- Coeficiente *Tau* de concordância

Antes de proceder à análise da acurácia, avaliou-se a confiabilidade da interpretação da imagem que serviu de base para a coleta de pontos de referência (ANEXO 6). Foi possível utilizar a imagem multiespectral como referência, pois feições reconhecidas no terreno tiveram certo grau de concordância como o interpretado na imagem. Considerou-se, então, a interpretação válida como referência, a matriz de erros de acordo com o teste de confiabilidade apresentado no ANEXO 6. Neste trabalho, considerou-se um baixo índice de acurácia valores para *Tau* inferior a 0,5.

A matriz de erros para a imagem classificada de acordo com a estrutura semântica é apresentada na Tabela 12. Foram amostrados aproximadamente 30 polígonos para cada classe de interesse. A acurácia média total é dada pela razão entre os polígonos corretamente classificados e o número total de polígonos amostrados  $a_t = 180/292 = 0,612$ . A acurácia total teve significância relativa, pois não considerou os erros de omissão e de comissão da matriz de confusão.

TABELA 12- MATRIZ DE ERROS  $PO_{ij}$  ACURÁCIA DO PRODUTOR,  $P_{i+}$  ACURÁCIA DO USUÁRIO.

REFERÊNCIA INTERPRETAÇÃO												
MAPA	Var.	Gal.	Pas.	Flo.	Euc.	Cap.	Sol.	Urb.	Can.	Cul.	$i+$	$P_{i+}$
Várzea	20	5	3	2							30	0,667
Galeria	5	18		1	3	1					28	0,643
Pastagem	1		16			8	3		3		31	0,516
Floresta	2	8		20	3	2					36	0,555
Eucalipto	1		2	3	16				1		23	0,696
Capoeirinha	3		5	1		18	1		4		32	0,563
S. Exposto	1		3				21	4	4		33	0,636
S. Urbano			2			1	5	15	0		23	0,652
Cana			3			4	5		19	2	33	0,576
Culturas			1			2			3	17	23	0,739
$+i$	33	31	35	27	22	36	35	19	34	19	292	
$PO_{+j}$	0,610	0,581	0,457	0,740	0,727	0,500	0,600	0,789	0,560	0,895		

É interessante observar na Tabela 12 que existiram objetos que foram atribuídos, erroneamente, a classes pouco prováveis devido a separabilidade ao nível espectral. Tomando como exemplo a classe *eucalipto* (6ª linha), dos 23 objetos coletados, um foi classificado como *várzea* e 2 objetos como *pastagem*, isto pode ser explicado pela detecção em campo de alguns indivíduos em áreas de *pastagem* e próximos ao ambiente *ciliar*. A Tabela 13 mostra o coeficiente de concordância para as diferentes classes da imagem classificada resultante da matriz de confusão da Tabela 12.

Considerou-se certa variabilidade para mais ou para menos de  $Tau$ , tendo em vista que não foram coletados pontos de referência *in loco*, mas sim por interpretação da imagem (ANEXO 6).

TABELA 13- ÍNDICE *TAU* DE CONCORDÂNCIA

<b>CLASSE</b>	<b>TAU</b>
Várzea	0,567
Galeria	0,534
Cana	0,511
Floresta	0,711
Pastagem	0,400
Eucalipto	0,700
Capoeirinha	0,444
Solo Exposto	0,560
S. Urbano	0,766
Outras Culturas	0,883
<b>Tau Geral</b>	<b>0,608</b>

### 5.6.3- Ambigüidades

As classificações fuzzy não puderam ser adequadamente avaliadas unicamente através da maneira convencional (matriz de confusão), uma vez que a regra de classificação adotada permitiu várias possibilidades de categorização a determinado objeto (GLEMSER & FRITSCH, 1998; BURROUGH & McDONNELL, 1998).

Propôs-se, então, embasar a confiabilidade da classificação extraindo do próprio classificador fuzzy os diferentes graus de pertinência de um objeto a diferentes classes. Avaliou-se a ambigüidade temática nominal dos objetos por meio de valores discretos (como descrito no item 4.4.1).

O método adotado foi uma adaptação do apresentado por TOWNSEND (2000) e LABA et al.(2002) baseado em estudos realizados por GOPAL & WOODCOCK (1994), que propõem uma análise fundamentada na observação numa escala lingüística que permite avaliar o grau de ambigüidade da classificação.

Utilizou-se, o índice de ambigüidade apresentado no item 4.4.1. Partiu-se do pressuposto que a proximidade entre graus de pertinência pode gerar alguma hesitação na



associação de um objeto à determinada classe. Quanto mais próximo de zero o índice de ambigüidade,  $I_a$ , menor certeza é observada.

Baseado no intervalo de 0 a 1 de  $I_a$ , optou-se pela adoção escala lingüística de acordo com o proposto abaixo:

1- $I_a = 0$ ;	classificação inaceitável;
2- $0,01 \leq I_a \leq 0,30$	classificação ambígua ;
3- $0,31 \leq I_a \leq 0,50$	classificação aceitável;
4- $0,51 \leq I_a \leq 0,80$	classificação boa
5- $0,81 \leq I_a \leq 1$	classificação muito boa

A Tabela 15 apresenta a relação entre ambigüidade e coeficiente de concordância.

Existe uma correlação entre a estabilidade do mapa temático e o coeficiente de concordância .

As classes com menores valores de  $Tau$ , em geral, mostraram ser mais ambíguas.

TABELA 14- ESTABILIDADE DA CLASSIFICAÇÃO FUZZY BASEADA NA REDE SEMÂNTICA.

CLASSE	MAIOR PERTINÊNCIA	2º MAIOR PERTINÊNCIA	$I_a$	AMBIGÜIDADE	$TAU$ $\tau$
Várzea	0,572	0,202	0,646	Boa	0,567
Galeria	0,290	0,180	0,380	Aceitável	0,534
Pastagem	0,317	0,201	0,366	Aceitável	0,400
Floresta	0,570	0,120	0,780	Boa	0,711
Eucalipto	0,699	0,179	0,743	Boa	0,700
Capoeirinha	0,477	0,451	0,054	Ambígua	0,444
Solo exposto	0,310	0,299	0,036	Ambígua	0,560
Solo Urbano	0,701	0,150	0,786	Boa	0,766
Cana	0,331	0,322	0,002	Ambígua	0,511
Outras Culturas	0,370	0,210	0,432	Aceitável	0,883

Nota-se no resultado da Tabela 14 que algumas classes como *capoeirinha* e *solo exposto* apresentaram certo grau de discrepância entre o coeficiente  $Tau$  e o índice de ambigüidade. Tomando, como exemplo *solo exposto*  $Tau = 0,560$  e  $I_a = 0,036$ , o índice  $I_a$  relaciona-se à classificação fuzzy, enquanto  $Tau$  relaciona-se ao mapa temático resultante. Apesar de *solo exposto* no mapa temático ter tido um índice de aceitação razoável no processo de classificação fuzzy, este mesmo obteve um valor de pertinência muito próximo a uma

segunda classe possível, *Solo urbano*. O índice de ambigüidade da classificação fuzzy nem sempre coincidiu com um índice baixo de concordância entre a imagem classificada e sua interpretação visual, de acordo com o apresentado na Tabela 14.

Os índices de ambigüidades aferiram apenas o quão dúbio ou instável é a associação de determinado objeto à determinada classe, durante o processo de “desfuzzificação”. Porém a incerteza mostrou apenas a possibilidade de se ter cometido um erro quando se optou por escolher o maior grau de pertinência como critério de associação.

#### 5.6.4- Coeficiente de Correlação

Considerando as imagens classificadas apoiadas em duas diferentes bases de conhecimento- **A= Floresta/Outros** (rede semântica) e **B= Urbano/Rural** (visão de outro especialista)- foi avaliado o grau de afinidade entre as duas imagens, considerando apenas os atributos dos objetos associados às seguintes classes: 1- *Floresta (galeria + não ciliar)*; 2- *Várzea*; 3- *Eucalipto*; 4- *Solo Exposto*; 5- *Solo Urbano*; 6- *Culturas*; 7- *Pastagem* e 8- *Capoeirinha*. Como algumas classes da imagem **A** pertenciam a diferentes grupos semânticos na imagem **B**, fez-se mister agrupar algumas classes e unificar a nomenclatura a fim de proceder à análise.

O resultado do teste de *Cramer's V* = 0.8391 revelou que as imagens temáticas **A** e **B** possuem um alto grau de afinidade ou similaridade, traduzindo um alto grau de concordância entre ambas em relação às classes citadas. Apesar das imagens temáticas terem sido classificadas apoiadas em diferentes contextos, elas foram bastante similares, o que mostrou um grau de consistência do classificador baseado na estrutura hierárquica resultante da segmentação por multi-resolução.

### 5.7- ANÁLISE DA APLICABILIDADE DA REDE SEMÂNTICA PARA UMA OUTRA ÁREA DE ESTUDO

A fim de avaliar a aplicabilidade da rede semântica proposta, foi selecionada uma outra área teste de características fitogeográficas similares, a qual situa-se na porção noroeste do Rio Paracatu no município de Atalaia, vizinho a Nova Esperança.

FIGURA 32- ÁREA TESTE MUNICÍPIO DE ATALAIA



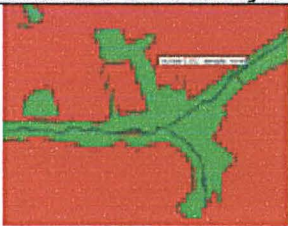
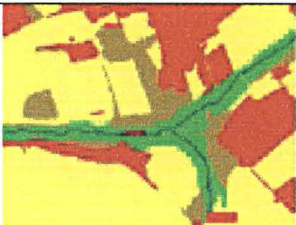

A imagem da Figura 32 foi segmentada e classificada da mesma forma da realizada no item 5.4.2.1. Obtiveram-se os resultados de acordo com a Tabela 15.

A rede semântica proposta no capítulo 4, Figura 16, foi adaptada para esta área de estudo. Classes como *eucalipto* e Solo *urbano* não foram consideradas. Tratando-se de um número menor de classes, menos descritores foram necessários. A instabilidade da classificação foi inferior à classificação de toda a área da imagem. Isto se deveu ao fato,

provavelmente, de se referir ao mesmo ambiente e por não ter apresentado grande variações fitogeográficas. Os descritores utilizados foram os mesmos apresentados na Tabela 9.

As regiões dos Municípios de Nova Esperança e Atalaia são bastante representativas, em termos de ocupação do solo, do Norte do Estado do Paraná, logo a aplicação desta rede resultante do conhecimento poderia ser expandida a regiões congêneres.

TABELA 15- CLASSIFICACAO BASEADA NA REDE SEMANTICA DE OUTRA ÁREA DA IMAGEM

NÍVEIS HIERÁRQUICOS	CLASSIFICAÇÃO
<ul style="list-style-type: none"> <li> <ul style="list-style-type: none"> <li>Nível 3 <ul style="list-style-type: none"> <li>Floresta</li> <li>outras</li> </ul> </li> <li>nível 2 <ul style="list-style-type: none"> <li>Floresta 2 <ul style="list-style-type: none"> <li>Ambiente Ciliar2</li> <li>Ambiente não Ciliar2</li> </ul> </li> <li>Outras 2 <ul style="list-style-type: none"> <li>agricultura2</li> <li>outras_na</li> </ul> </li> </ul> </li> <li>rio</li> <li>nível 1 <ul style="list-style-type: none"> <li>outras_na1 <ul style="list-style-type: none"> <li>solo exposto</li> <li>pastagem</li> </ul> </li> <li>agricultura 1 <ul style="list-style-type: none"> <li>outras culturas</li> <li>cana</li> </ul> </li> <li>Ambiente não Ciliar1 <ul style="list-style-type: none"> <li>floresta</li> <li>capoeirinha</li> </ul> </li> <li>Ambiente Ciliar1 <ul style="list-style-type: none"> <li>mata de galeria</li> <li>varzea</li> </ul> </li> </ul> </li> </ul> </li></ul>	 <p>3</p>
	 <p>2</p>
	 <p>1</p>

## 5.8- ANÁLISE COMPARATIVA ENTRE A CLASSIFICAÇÃO BASEADA EM OBJETOS E A FOTOINTERPRETAÇÃO

A interpretação das feições da imagem demandou principalmente o conhecimento do observador sobre a cena. A cognição gerou um processo intuitivo no qual se identificou a semântica da feição representada na cena. Observou-se no processo de classificação, que a capacidade do cérebro humano, especialmente em correlacionar o significado semântico de uma feição com a capacidade de percepção visual, foi inigualável e dificilmente pode ser

automatizada. Contudo, percebe-se que a inserção do conhecimento na estrutura hierárquica dos objetos simulou de maneira simplificada o raciocínio humano.

O resultado apresentado no item 5.1 (interpretação visual da imagem nos três domínios) pôde ser comparado com os descritores utilizados na classificação de acordo com a Tabela 16. A interpretação da imagem possibilitou a identificação simultânea de um maior número de elementos, que agrupados auxiliou a elaboração da semântica da cena. Alguns destes elementos foram quantificados e serviram de parâmetros a regras fuzzy. Contudo, nem todos elementos percebidos na imagem podem ser processados de mesma maneira pelo classificador, a divergência entre a máquina e o cérebro humano não pode ser eliminada (Tabela 16).

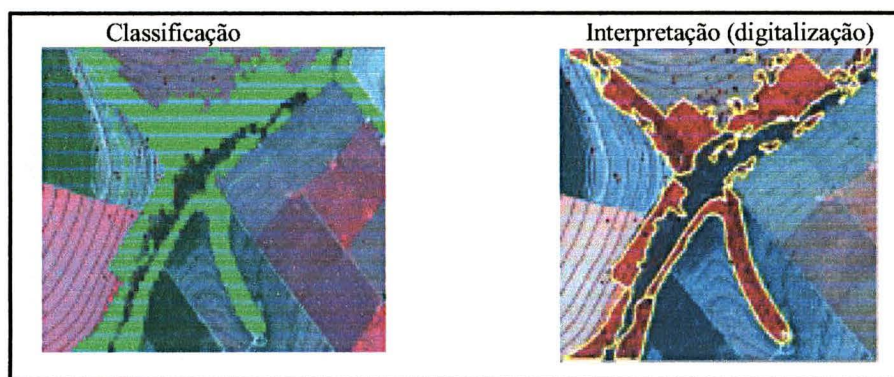
TABELA 16- COMPARAÇÃO ENTRE OS ELEMENTOS DA FOTOINTERPRETAÇÃO E DESCRITORES

CLASSES	ELEMENTOS DE INTERPRETAÇÃO	DESCRIPTOR E CLASSIFICAÇÃO
<i>Várzea</i>	Cor, forma	Cor e contexto
<i>Eucalipto</i>	Cor, Forma, Textura	Cor
<i>Mata de Galeria</i>	Cor, Forma	Contexto
<i>Floresta (reserva)</i>	Cor, Forma, Textura	Cor, contexto
<i>Solo urbano</i>	Cor, Forma, Textura, padrão	Textura e forma
<i>Solo Exposto</i>	Cor, Forma	Textura, Contexto

Na Figura 33, observa-se que as formas dos objetos fotointerpretados se parecem mais com os que são representados no mundo real, se comparados àqueles segmentados e posteriormente classificados, apesar da subjetividade da interpretação. Os objetos agrupados são uma mera aproximação daquilo que é percebido no mundo real. Os contornos dos objetos são de certa forma fuzzy, pois dependem dos critérios de semelhança adotado. Existe, sem dúvida, uma discrepância entre os contornos das classes representada na Figura 33 e os objetos classificados.



FIGURA 33- COMPARAÇÃO DA CLASSIFICAÇÃO E INTERPRETAÇÃO  
(AMBIENTE CILIAR)



A fotointerpretação auxiliou substancialmente o grau de eficiência da classificação orientada a objeto, pois de certa maneira o conhecimento adquirido durante a fase de interpretação pôde ser quase que totalmente introduzido no processamento da imagem. No entanto, a eficácia do classificador fuzzy não foi suficiente para retratar fielmente o que se observava na imagem. Os descritores adotados foram elementos derivados da segmentação, o que de certa forma, divergem dos elementos de percepção visual da cena. Não obstante, o método de classificação adotado superou os convencionais por se aproximar mais do raciocínio humano no que se refere aos seguintes aspectos:

- Objetos foram mais facilmente percebidos pelo cérebro humano que pixels;
- Estabeleceram-se relações entre objetos;
- Possibilitou a introdução do conhecimento *a priori*;
- Estruturação lógica dos atributos.

A classificação consistiu de duas estratégias principais: a representação orientada a objeto da informação da imagem em diferentes escalas (Multi-resolução) e representação do conhecimento por meio de rede semântica. Apesar da metodologia adotada mostrar um alto grau de eficiência, principalmente no que se refere à realização de relações entre objetos

hierarquicamente estruturados, possibilitando a inclusão de abstrações, ainda assim observou-se que a intervenção humana direta é insuperável considerando os fatores abaixo:

- Percepção eficaz de características de cor, textura e forma ;
- Relação intuitiva entre a feição e sua semântica baseada na percepção cognitiva;
- Limites das feições suavizados e próximos à realidade;

Na imagem da Figura 32 foi realizada a interpretação visual apenas para o ambiente ciliar. Tal interpretação foi comparada com as classificações realizadas ao nível de pixel e ao nível de objetos. Os resultados observados confirmam a eficácia do método proposto, de acordo com Tabela 17.

TABELA 17- COEFICIENTE CRAMER'S V PARA A FOTOINTERPRETAÇÃO E IMAGENS CLASSIFICADAS

<b>CLASSIFICAÇÕES</b>	<b>CRAMER</b>
<b>Máxima-verossimilhança</b>	0,450
<b>Fuzzy</b>	0,521
<b>Orientação a objeto</b>	0,806

A possibilidade de modelagem da cena em diferentes escalas simultaneamente (níveis hierárquicos) permitiu uma análise explícita da estrutura contextual dos elementos da cena. A metodologia apresentada foi tecnicamente de interesse para classificação de ambiente ciliar e de outros temas circunvizinhos (*solo urbano, agricultura, etc*), por permitir a inserção do conhecimento, de forma a contribuir para uma interpretação mais coerente da estrutura da cena e sua representação- em diferentes níveis de generalização. Ressalta-se que esse tipo de análise possibilitou avaliar a representação de entidades geográficas em diversos níveis de abstração, a partir de uma simples imagem multiespectral.

## 6- CONCLUSÕES E RECOMENDAÇÕES

### 6.1- CONCLUSÕES

Baseado no que foi apresentado neste trabalho pôde-se chegar às seguintes conclusões:

- A otimização da extração de informação em imagem de alta resolução requer análises que transcendem o nível de pixel. Confirma-se o fato já recentemente comentado por muitos autores: a classificação baseada ao nível de pixel, seja por regra fuzzy, ou por métodos paramétricos não permite fazer o amplo uso das potencialidades espectral e espacial;
- A classificação baseada em objetos oriundos de multi-resolução, através do algoritmo FNEA( *fractal net evolution analysis*), mostrou-se superior à métodos paramétricos ao nível de pixel (ex.: máxima verossimilhança), em termos de discriminação de tipologias vegetais do ambiente ciliar;
- A interpretação da imagem segmentada é tão importante quanto a interpretação multiespectral, uma vez que as propriedades espaciais, tais como forma, tamanho e orientação, são bem evidentes. Os objetos da imagem, quando associados aos pixels que lhe deram origem, conduzem a uma percepção menos abstrata da cena;
- A segmentação da imagem em diferentes escalas ou níveis é a base para contextualizar superobjetos e subobjetos de maneira a introduzir uma estrutura que permite a inserção da hierarquia. É a rede hierárquica o fundamento do cógico, e explicitado através de uma rede semântica dentro de uma sintaxe fuzzy;
- A lógica fuzzy mostrou-se um instrumento apropriado na modelagem do processo cognitivo, propiciando a consideração de dubiedade no processo que associa determinado objeto a uma determinada categoria;



- A estruturação de uma rede semântica *a priori* baseada no contexto tanto ao nível de objetos, quanto ao nível do ambiente ciliar, mostra-se mais adequada que outras formas de classificação testadas. A relação dos objetos entre os diferentes níveis permite inserir eficientemente o contexto. Textura e forma passam a assumir um papel significativo na elaboração de regras de fuzzy;
- Uma vez comparado o potencial discriminatório da classificação pelo processo de especialização (hierárquico) com a classificação seletiva, observa-se um melhor resultado por meio da especialização, pois os diferentes níveis de segmentação impõem às relações entre objetos que por si só são discriminatórias;
- Quando a relação entre objetos e subobjetos é levada em conta através de uma rede semântica, menos descritores fuzzy são necessários, o que pode diminuir a ambigüidade da classificação;
- Depreende-se que a classificação contextual, aqui definida, não se refere tão somente à incorporação de relações espaciais entre objetos, mas também ao conjunto de circunstâncias que acompanham um conhecimento. O contexto transcende a topologia uma vez que informações temáticas podem ser inseridas;
- Para a análise de acurácia da imagem temática, a determinação da matriz de erros pode não ser suficiente. Tratando-se de um classificador baseado em regras fuzzy sugere-se a avaliação de ambigüidades as quais possuem uma certa correlação com o coeficiente *Tau* de concordância.

## 6.2- SUGESTÕES E RECOMENDAÇÕES

- O processo de especialização em diferentes níveis hierárquicos deve otimizar a discriminação de um maior número possível de classes a um nível mais geral. A quantidade de níveis hierárquicos deve ser proporcional à rede semântica definida *a priori*;
- As imagens de sensoriamento remoto tendem a possuir resoluções ainda maiores com novos sensores: logo novas possibilidades de segmentação devem ser avaliadas, tal como a sugerida por PESARI & BENEDIKTSSON (2002) baseada no espectro morfológico, onde o objeto na imagem é definido como um componente de pixels que compartilham da mesma característica morfológica;
- Existem descritores fuzzy que não foram utilizados no esquema de regras de classificação. Recomenda-se que um maior número de descritores de forma sejam testados nos diferentes níveis de segmentação. A escolha dos descritores deve ser intencional. Para cada descritor (forma, textura, brilho) escolhido deve-se perceber a razão da escolha, porque um descritor se distingue de outro. Se determinado parâmetro descrever bem alguma classe, não se faz mister selecionar outros descritores. O uso de um grande número de descritores pode causar certa instabilidade na classificação;
- A análise de textura baseada em matriz de co-ocorrência GLCM ( *grey level co-occurrence matrix*) deve ser testada a nível de objetos com a finalidade de obterem novos descritores;
- Tendo em vista que a classificação contextual não é um processo determinístico, deve-se avaliar de que forma as relações hierárquicas entre as classes e seus descritores são dependentes. Dependências mútuas entre classes deveriam ser evitadas. A *classe A*

não deveria ser descrita pelas mesmas regras que se referem à *classe B*, se *classe B* depende da *classe A*. Este tipo de análise também seria interessante para a avaliação da estabilidade da classificação;

- Uma vez que pixels mistos dominam as imagens de sensoriamento remoto e não desaparecem nas imagens de alta resolução, é necessária sua inclusão na avaliação de acurácia da imagem classificada. A avaliação da acurácia por regras fuzzy ainda é um tema aberto e necessita de estudos mais aprofundados;
- A acurácia geométrica dos polígonos gerados merece um estudo mais aprofundado, visto que o limite entre duas ou mais classes em geral é variável;

## GLOSSÁRIO

**Acurácia:** O significado estatístico de acurácia se refere ao grau que a média estimada de uma grandeza difere da média real.

**Acurácia do Produtor:** A acurácia do produtor para uma determinada categoria é expressa pelo número de *pixels* ou *objetos* corretamente classificados pelo número total de *pixel* ou *objetos* de referência atribuídos a essa categoria. Refere-se à probabilidade de um *pixel* ou *objeto* de referência ter sido corretamente classificado, computando os erros de omissão ou exclusão.

**Acurácia do Usuário:** É determinada pela razão do total de *pixels* ou *objetos* corretamente classificados pelo total de *pixels* ou *objetos* amostrados para essa categoria. Refere a probabilidade de que um *pixel* ou *objeto* classificado na imagem (mapa) represente a mesma categoria no terreno, computando aos erros de inclusão ou comissão.

**Atributo:** Informação não gráfica associada aos objetos;

**Classe:** categoria de determinado objeto ou região.

**Cognição:** Sinônimo de conhecer. O termo se relaciona a ação de raciocinar, emitir, perceber e compreender conceitos, recordar, imaginar.

**Contexto espacial:** Conhecimento de relações de vizinhança entre pixels ou objetos. Pode também ser entendido como grau de correlação entre objetos vizinhos.

**Contexto temático:** Conjunto de circunstâncias que acompanham um conhecimento.

**Descritor:** Código ou valor numérico usado para identificar um nome de arquivo ou um parâmetro.

**Espaço dos Atributos:** Gráfico contendo as frequências de distribuição de duas intensidades de duas diferentes bandas espectrais.

**Estocástico:** Refere-se a processo que dependem das leis do acaso.

**Estrutura Hierárquica:** Método de organizar os objetos e subobjetos de forma ordenada relacionada em níveis de informação.

**Feição:** Delineamento de traços fisionômicos de determinada classe no domínio da cena. Pode ser também compreendido por um objeto ou um conjunto de objetos que compõem uma classe no mundo real.

**Fractal:** Refere-se a representação de imagens através de frações de objetos ou superfícies irregulares como nuvens montanhas e objetos irregulares, etc., utilizando-se de procedimentos matemáticos que tratam dimensões fracionárias (infimamente pequenas). Um objeto é um fractal se a dimensão Hausdorff-Besicovitch excede a dimensão Euclidiana, sendo fractal um objeto que possui detalhes em todas as escalas espaciais.

**Fuzzy ou lógica fuzzy:** Tipo de lógica aplicada à programação de computadores, que tenta imitar os métodos de raciocínio do cérebro humano.

**Generalização:** Processo de redução de detalhes dos objetos como consequência da redução da escala.

**Grupo semântico:** Refere-se a um conjunto de classes que possuem graus de parentesco ou significância.

**Herança:** Em uma base de dados de conhecimento, as ocorrências de uma classe devem ter todas as propriedades das classes mais gerais das quais são membros.

**Heurística:** Hipótese que, numa pesquisa, leva a descoberta científica, método analítico para a descoberta de verdades científicas.

**Lógica Booleana:** Proposta pelo matemático Inglês George Boole (1815-1864), baseia-se em estabelecer limites determinados a partir de informações consideradas falsas, atributo zero, e verdadeiras atributo 1.

**Mapa temático:** Mapa que mostra selecionados tipos de informações espacialmente referenciadas concernentes a um determinado tema.

**Modelo conceitual:** Abstração, representação e ordenação de um fenômeno utilizando a base do conhecimento.

**Modelo digital do terreno:** Modelo quantitativo de elevação de determinada porção da superfície terrestre.

**Nível de segmentação :** Refere-se ao parâmetro de escala adotado e o grau de generalização hierarquicamente estruturado.

**Objeto:** Elemento da imagem segmentada composto por um conjunto de pixels com características similares. Pode também ser entendido como variável usada em um sistema especialista dentro de uma operação de raciocínio.

**Orientação a objeto:** Refere-se a representação de feições da imagem em objetos ou segmentos originados a partir de segmentação. O processamento da imagem ocorre ao nível de objeto.

**Parâmetro:** Informação ou valor que define os limites das funções de pertinência.

**Parâmetro escala:** Variável que permite determinar o limite máximo de heterogeneidade do processo de segmentação. É responsável também pelo tamanho e grau de detalhe dos objetos da imagem.

**Parâmetro de forma:** Refere-se ao critério de forma utilizado na segmentação. Compreende a suavidade e a compacidade dos objetos.

**Rede semântica:** Estrutura lógica que relaciona os objetos ou classes de acordo com seus significados e relações.

**Região:** Agrupamento de dois ou mais objetos com características evidentes que se distinguem de outros objetos.

**Regras Fuzzy:** Conjunto de condições baseadas em lógica fuzzy que descreve determinada situação.

**Semântica:** Refere-se ao significado dos objetos dentro de determinado contexto temático.

**Sintaxe:** Regras gramaticais aplicadas a uma linguagem de programação.

**Superfície de Decisão:** Refere-se ao delineamento de classes por meio de regiões no espaço multiespectral. Estas regiões são separadas por superfícies onde as funções discriminantes que unem as classes espectrais são iguais.

**Superobjetos:** Objetos formados pela fusão de dois ou mais objetos obedecendo a determinado critério de similaridade. Superobjeto muitas vezes pode ser confundido como região .

**Topologia:** Termo usado para referir-se a continuidade do espaço e propriedades espaciais, como conectividade. Estas propriedades não são afetadas quando distorcidas (mudança de sistema de projeções). Na representação de entidades vetoriais conectividade é definida explicitamente por uma junção descrevendo objetos, que de alguma forma estão ligadas no espaço (ex. junção entre dois rios).

**Unidade fitogeográfica:** Refere-se a uma região coberta por vegetação de mesmo aspecto fisionômico (Ex: Ambiente Ciliar).

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALHAJJ, R., POLAT, F. **Ruled-based schema in objected-oriented databases.** Knowledge-Based System n<sup>o</sup>16. Elsevier. 2002.
- ALTMAN, D. **Fuzzy set theoretic approaches for handling imprecision in spatial analysis.** International Journal of GIS, vol 8, n<sup>o</sup> 3, p.271-289. 1994.
- ANTUNES, A.F & LINGNAU, C. **Uso de índices de acurácia para avaliação de mapas temáticos obtidos por meio de classificação digital.** Anais GIS Brasil, Curitiba. 1997. CD-ROM
- AKTINKSON, P.M & LEWIS.P. **Geoestatistical classification for remote sensing: an introduction.** Computer & Geosciences. Pergamon. n<sup>o</sup> 26. p.361-371. 2000.
- AVERY, T.E, BERLIN, G. **Fundamentals of remote sensing and airphoto interpretation.** Prentice Hall. Quinta Edição. 1993.
- AZEVEDO et al. **Redes neurais com aplicações em controle em sistema especialista.** Visual books. Florianópolis. 2000.
- BAATZ, M & SCHÄPE, A. **Objected oriented and multiscale image analysis in semantic network.** 2<sup>nd</sup> International Symposium on operational Remote Sensing. ITC. Netherlands. 1999.
- BAATZ, M & SCHÄPE, A. **Mutiresolution segmentation: an optimization approach for high quality multi-scale image segmentation.** München. Disponível em <www.definiens.com> Acesso em março 2001.
- BAATZ et al. **Tutorial of e-Cognition Software- Methods and Concepts.** München. Disponível em <www.definiens.com> Acesso em março 2001.
- BÁRDOSSY, A & SAMANIEGO, L. **Fuzzy rule-based classification of remotely sensed imagery.** IEEE Transactions on Geosciences and Remote Sensing, Vol 40, n<sup>o</sup> 2. 2002.
- BÄHR, P. **Models in philosophy and in image analysis.** Universität Karlsruhe, Institut für Photogrammetrie und Fernerkundung. ISPRS, extended abstract, comm. II, 2002.

BAUER, T; STEINNOCHER, K. **Per-parcel land use classification in urban areas applying a rule-based technique**. Disponivel em:<[www.defeniens.com/publication.pdf](http://www.defeniens.com/publication.pdf)> Acesso em jan. 2002.

BENZ, Ursula.1999. **Supervised Fuzzy analysis of single and multichannel SAR data**. IEEE Transactions on Geosciences and Remote Sensing, Vol 37, nº 2. 2000.

BENZ, U; BAATZ, M; SCHREIER, G. **Object oriented segmentation and classification of advanced radar allow automated information extraction**. Proceedings IGARSS 2001. CD-ROM.

BERENDT et al. **Spatial representation with aspects maps**. Cognition: an interdisciplinary approach to representing and processing spatial knowledge. Edited by Christian Freksa, Christopher Habel e Karl Wender, Springer-Verlag, Berlin. p.313-336.1998.

BERTIN, J. **Semiology of graphics- diagram networks maps**. Wisconsin, University Press, 1983.

BEZDEK, J.;PAL, N. **Fuzzy model for pattern recognition**. IEEE Transaction on Geoscience and Remote Sensing. nº 3.1992.

BINAGHI, et al. **Fuzzy contextual classification of multisource remote sensing images**. IEEE transactions on Geosciences and Remote Sensing, vol35, n 7. 1997.

BISHR, Y. **Semantic aspects of interoperable GIS**. ITC publication n 56, Enschede. 1997.

BLASCHKE, T.; HAY G. **Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structure**. Disponivel em:<[www.defeniens.com/publication.pdf](http://www.defeniens.com/publication.pdf)> Acesso em jan. 2002.

BLASCHKE, LANG, S; LORUP,E; ZIEL, P. **Object-oriented image processing in an integrated GIS/RS environment and perspectives for environmental applications**. In: Umweltinformation für Planung Politik und öffentlichkeit. Marburg. Verlag. Vol2, p.555-570. 2001.

BLASCHKE, T, LANG, S, LORUP, E, STROBL, J & ZEIL, P. **Objected oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications**. Environmental information for planning. Vol 2. Metropolis-Verlag. 2000.

BRADSHAW, Ben, **Semantic Based Image Retrieval: A Probabilistic Approach**, Microsoft Research, Cambridge, England. 2000.

BÜCKNER, J. KOCH, H. PAKZAD, K. **Knowledge based interpretation of objects in topographic maps and moorlands in aerial images**. Semantic Modeling for Acquisition of Topographic Information from Images and Maps, Edited by Förstner Lutz Plümer. München. 1999.

BURROUGH, P.; FRANK, A. **Geographic objects with Inderterminate boundaries**. Francis & Taylor, 1996.

BURROUGH, P.; McDONNELL, R. A. **Principles of Geographical Information System**. Oxford: Oxford Uni. Press, 1998.

CAMARA, G; MEDEIROS, J. **Operações de análise geográfica**. Sistemas de Informações Geográficas, Aplicações em Agricultura. Editado por Eduardo Assad e Edson Sano. EMBRAPA, 2º edição . p.67-90.1998

CENTENO, J, C. et al. **Análise da forma em imagens temáticas**. Anais do Colóquio Brasileiro em Ciências Geodésicas, UFPR, Curitiba. 2001. CD-ROM.

CHUVIECO, E. **Fundamentos em teledetecccion especial**. Ediciones Rialp. Madri.1990

CLÉMENT, Veronique et al. **Interpretation of remotely sensed images in a context of multisensor fusion using a multispectral architecture**. IEEE Transations on Geoscience and Remote Sensing. vol.31,nº 4, p.779-791. 1993.

CONGALTON, R & GREEN, K. **A pratical look at sources of confusion in error matrix generation**. Photogrammetric Engineering & Remote Sensing, Vol59, nº5, p 641-644. 1993a.

CONGALTON, R; GREEN, K 1999. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Lewis Publishers, USA.1999b.

COUCLERIS, H. **Space, Time, Geography. Geographical Information Systems**. P.Longley, M. Goodchild, D. Maguire and D. Rhind. New York, John Wiley: p. 29-38.1999.

DEFINIENS IMAGING, **ecognition, User's Guide 3.0**. Disponível em <http://www.definiens-imaging.com/documents/index.htm> . Acesso em jan. 2003



DURIEUX, L et al. **Fuzzy classification by region of segmented NOAA- AVHRR images and multisource data.** In X SBSR Simpósio de Sensoriamento Remoto, Foz do Iguaçu. 2001. 1 CD-ROM.

EASTMANN, R. **Idrisi 32 release 2 tutorial.** University of Clark. Wocester, USA. 2001. 1 CD-ROM.

EASTMAN, J.R & JIANG. **Fuzzy measures in multi-criteria evaluation.** Proceedings, Second International Symposium on Spacial Accuracy Assessment in Natural Resources and Environmental Studies. For Collins. CO, p.527-534.1997.

E-COGNITION, **Concepts and Methods-Tutorial.** Difeniens, Muchen.2002.

FAN, G.; XIA, X. 2001. **A joint multicontext and multiscale approach to Bayesian image segmentation.** IEEE Transaction on Geoscience and Remote Sensing. Vol 39, nº 2, p. 2680-2688.

FABER, A., FÖRSTNER, W. Scale characteristics of local autocovariances for texture segmentation. International archives of photogrammetric and remote sensing, vol 32, Valladolid, Spain. 1999.

FISCHLER, M & FIRSCHEIN,O. **Intelligence, the eye, the brain and the computer.** Addison-Wesley Publishing Company. 1987.

FRANK, A. **Formal models for cognition- taxonomy of spacial location description and frames of reference.** Spacial Cognition: an interdiciplinary approach to representing and processing spatial knowledge. Edited by Christian Freksa, Christopher Habel e Karl Wender Springer-Verlag, Berlin. p293-336.1998.

FRANK, A; RAUBAL, M. **Formal specficication of image schemata- a step towards interoperability in geographic information systems.** Spatial Cognition and Computation 1: p 67-101. The Netherlands. 1999.

FRANKLIN, S; WULDER, A; LAVIGNE, M.B. **Automated derivation of geographic windows for use in remote sensing digital image texture analysis.** Computer & Geosciences, 22, p. 665-673. 1996.

FRANKLIN, S; MAUDIE, A; LAVIGNE, M.B. **Using spatial co-ocurrance texture to increase forest structure and species composition classification accuracy.** Photogrammetric Engineering & Remote Sensing, Vo.67, p.849-855. 2001.

FOODY, G. **Status of land cover classification accuracy assessment.** Remote Sensing for Environment, p.185-201.2002.

FU, K. S & MUI, J.K. **A Survey on image segmentation.** Pergamon Press LTDA. Pattern Recognition Vol.13, p..3-16. 1981.

GEHRKE J, HOMMEL B. **Impact of exogenous factors on special Coding in perception and memory.** In Spatial Cognition an interdisciplinary approach to representing and processing spatial knowledge. Springer. p.63-78. 1998

GERLACH, F. **Characteristics of space imaging's one-meter resolution satellite imagery products.** In international archives of Photogrammetry and Remote Sensing. Vol XXXIII. Amsterdam. 2000. 1 CD-ROM.

GLEMSER, M; FRITSCH, D. **Data uncertainty in hybrid GIS.** IAPRS, Vol 32, Stuttgart. 1998.

GRIFFIOEN, J; MEHROTRA, R; YAVATKA, R. **An Object-Oriented Model for Image Information Representation.** Department of Computer Science .University of Kentucky <ms.uky.edu> acesso junho 2002.

GONZALEZ, R & WOODS, R. **Processamento de imagens digitais.** Ed. Edgard Blucher, São Paulo 2000.

GORTE, B. **Probabilist segmentation of remote sensing data.** ITC, Journal, Nº 63, The Netherlands. 1998.

GUNST,M.; VOSSelman, G. **A semantic road model for aerial image Interpretation.** In Semantic Modeling for Acquisition of Topographic Information from Images and Maps, Edited by Förstner Lutz Plümer. Verlag. Berlin. 1997.

HARALICK, M; DHANMUNGAN, K & DINSTEIN, I. **Textural features in image classification.** IEEE transactions on systems. Vol.Smc-3, nº 6, p.610-621. 1973.

HOFMANN, P. **Detecting urban features from Ikonos data using an objected-oriented approach.** PRSPS 2001 Proceedings. Disponivel em [www.definiens.com/documents.pdf](http://www.definiens.com/documents.pdf), acesso março 2002a.

HOFMANN, P. **Detecting informal settlements from ikonos image data using methods of object oriented image analysis – an example from Cape Town (South Africa)** Disponivel em [www.definiens.com/documents.pdf](http://www.definiens.com/documents.pdf), acesso março 2002b.

HOFMANN, T. et al. **Unsupervised texture segmentation in a deterministic annealing framework.** IEEE transactions on pattern analysis and machine intelligence. Vol 20, n 8, p.803-818. 1998.

HOFMANN, P & REINHARDT W. **The extraction of GIS features from high resolution imagery using advanced methods based on additional contextual information- first experiences.** International Archives of Photogrammetry and Remote Sensing Symposium. Vol XXXIII, Part 4. Amsterdam. 2000. 1 CD-ROM.

HORD, R. M.& BROONER, W. **Land Use map-accuracy criteria.** Photogrammetric Engineering & Remote Sensing, nº5, p.671-677, 1976.

IRON, J & PETERSON , G. **Texture Transform of Remote Sensing Data.** Remote Sensing for Environment 11, p.359-379. 1981.

IVITS, E., KOCH, B. **Object-Oriented remote sensing tools for biodiversity assessment : European Approach.** University of Freiburg, DE. Disponível em <[www.uni-freiburg.de/felis](http://www.uni-freiburg.de/felis)>. Acesso em dez. 2002.

JANSENN, L & MOLENAAR, M. **Terrain objects, their dynamics and their monitoring by integration of GIS and Remote Sensing.** IEEE transaction on Geoscience and Remote Sensing. Vol.33. 1995.

JENSEN, J. **Introductory Digital Image Processing: A Remote Sensing Perspective.** Englewood Cliffs, New Jersey: Prentice-Hall. 1996.

KANADE, T. **Region segmentation: signal vs semantics.** In Computer Graphics and Image Processing, no 13, p.279-297.1981.

KENDEL, M. **Multivariate Analysis.** Charles Griffin & Company. London. Second edition. 1980.

KIEMA, J. B. K. **Texture analysis and data fusion in the extraction of topographic objects from satellite imagery.** Journal of. Remote Sensing. Taylor & Francis. vol. 23, n 4, p.767-776. 2001.

KNAUFF, M. et al. **Mental models in spatial reasoning.** In Spatial Cognition: an interdisciplinary approach to representing and processing spacial knowledge. Springer-Verlag, Berlin. p.267-291.1998.

KOCH, H.; PAKZAD, R.; TÖNJES, R. **Knowledge based interpretation of aerial images and maps using a digital landscape model as partial interpretation.** Semantic Modeling for Acquisition of Topographic Information from Images and Maps, Edited by Förstner Lutz Plümer. Verlag. Berlin. 1997.

KOK, R., SCHNEIDER, T., ARMER, U. **Object-based classification and application in alpine Forest environment.** International Archives of Photogrammetry and Remote Sensing, vol 32, vol32. Valladolid. Espanha. 1999.

KOK, R., SCHNEIDER, T. ARMER, U. **Object based image analysis of high resolution data in the alpine forest area.** Lehrstuhl Für Landnutzungsplanung und Naturschutz, am Hochanger, Freising. ISPRS, Amsterdam. 2000. 1 CD-ROM.

KOURGLI, A. BELHADJ-AISSA. **Textural classification using textural signatures.** Proceedings of European Association of Remote Sensing. Rotterdam.p.557-561. 2000.

KUFONYI, O. **An introduction to object-oriented data structures.** ITC-Journal.1995-1. Enschede. 1995.

KUNYOSHI, Y; RODERJAN, C. **Vegetação: formações florestais do Brasil.** Cadernos Técnicos FUPF. UFPR. Curitiba. 1987.

KUNZ, D. **Integrated analysis of image and map data based on disjoint objects.** Semantic Modeling for Acquisition of Topographic Information from Images and Maps, Edited by Förstner Lutz Plümer. München. 1999.

KUSHWAHA, S.P.S et al. **Applications of Image Texture in Forest Classification.** Int. Journal of R.sensing, vol 15, p.2273-2284. 1994.

LABA, M et al. **Conventional and fuzzy accuracy assessment of New York gap analysis project land cover map.** In Remote Sensing of Environment. 81 p.443-455. 2002.

LAGACHERIE, P et al. **Fuzziness and uncertainty of soil boundaries: from reality of coding GIS.** Geographic Objects with Indeterminate Boundaries. Gisdata 2. Taylor & Francis. 1996.

LEE, S & ZHU, Q. **Fuzzy and evidence reasoning.** Spring-Verlag. Germany. 1995.

LEHMANN, F. **Semantic Networks in Artificial Intelligence,** Pergamon Press, Oxford. Also published as a special issue of Computers and Mathematics with Applications .1994

LEITE, P. **As diferentes unidades fitoecológicas da região sul do Brasil. Proposta de classificação.** Dissertação de Mestrado, Curso de Eng. Florestal. UFPR. Curitiba. 1994.

LINGNAU, C et al. **Ambiente Ciliar Uma Nova Abordagem de Planejamento Estratégico para Recuperação.** FUPEF 2002. Relatório Técnico.

LIU, X-H et al. **Integration of classification methods for mprovement of land-cover map accuracy.** ISPRS Journal of Phogrammetry and R. Sensing. vol. 56, p. 257-268. 2001.

LOPES, R. **Image segmentation lectures notes.** LSA/USP. Disponível em <[www.lsi.usp.br/~roseli/pee5830/pee5830\\_aula06.pdf](http://www.lsi.usp.br/~roseli/pee5830/pee5830_aula06.pdf)>. Acesso em jan. 2002.

MA, Z & REDMOND, R. **Tau coefficient for accuracy assessment of classification of remote sensing data.** In: Photogrammetric Engineering and Remote Sensing, vol. 68. p.435-439. 1995.

MECKLENBRÄUKER, S. et al. **Spatial information and action.** Spatial Cognition: an interdisciplinary approach to representing and processing spatial knowledge. Edited by Christian Freksa, Christopher Habel e Karl Wender, Springer-Verlag, Berlin. p.39-62.1998.

METTERNICHT, G. **Change detection assessment using fuzzy sets and remotely sensed data: an application in topographic maps revision.** ISPRS Journal of Photogrammetry and Remote Sensing, vol. 54. p.221-233. 1999.

MEINEL, G.; NEUBERT, M.; REDER, J. **The potential use of very high resolution satellite data for urban areas –first experiences with ikonos data, their classification and application in urban planning and environmental monitoring.** Disponível em:<[www.defeniens.com/publication.pdf](http://www.defeniens.com/publication.pdf)> Acesso em jan. 2002.

MIRANDA, F.P.; FONSECA, L.E.N. **Semi-variogram textural classification of JERS\_1 SAR data obtained over flooded area of the Amazon rainforest.** International Journal of Remote Sensing. Nº 19, p.549-556. 1998.

MOLENAAR, Martien. **An introduction to the theory of object Modelling for GIS.** Taylor&Francis, 1998.

MOLENAAR, M & CHENG, T. **Fuzzy spatial objects and their dynamics.** ISPRS Journal of Photogrammetry & Remote Sensing, n 55, p.164–175. 2000.

MUELLER, C. **Gestão de matas ciliares.** Gestão Ambiental no Brasil. Editora Fundação Getúlio Vargas. p. 185-214. 2001.

MUMBY, B; EDWARDS, A. **Mapping marine environments with IKONOS imagery: enhanced spatial resolution can deliver greater thematic accuracy.** Remote Sensing of Environment. 82, p.248-257 2002.

NAESSET, E. **Conditional Tau coefficient for assessment of producer's accuracy of classified remotely sensed data.** ISPRS Journal of Photogrammetry, Elsevier, vol.51, p 91-98. 1996.

OLMO, Chica.; HERNANDEZ Abarca. **Computing geostatistical image texture for remoted sensed data classification.** Computers & Geosciences. vol 26. p.373-383. 2000.

PALMER, M. W. **Fractal geometry: a tool for describing spatial patterns of plant communities.** Vegetatio, n° 75, p. 91-102, 1988.

PESARI, M., BENEDIKTSSON, J.A. **A new approach for morphological segmentation in high resolution satellite imagery.** IEEE Transaction on Geoscience and Remote Sensing. Vol 39, n 2. 2001.

PETERSON, P. **Interactive and animated cartography.** Prentice Hall Series in GIS. New Jersey. 1995.

QUINT, F. **Aerial image understanding using digital map-based semantic model.** Institut for Photogrammetry and Remote Sensing. University of Karlsruhe. 1997.

RICHARDS, J & JIA, X. **Remote Sensing Image Analysis, an Introduction.** Springer-Verlag. Berlin. 1999.

RODERJAN et al. **As unidades fitogeográficas do Estado do Paraná.** In Ciência e Ambiente. UFSM. p.75-92. janeiro/junho 2002.

ROSENFELD, G.H; LINS-FITZPATRICK, K. **Sampling for thematic map accuracy testing.** In Photogrammetric Eng. & Remote Sensing. Vol 48, n 1, p131-137. 1982.

SAHOO, P. SOLTANI, S. WONG, K. **A survey of thresholding techniques.** In Computer Vision, Graphics and Image Processing 41, p.233-260. 1988.

SCHIEWE, J , TUFTE, G, EHLERS, M. **Potencial and problems of multi-scale segmentation methods in remote sensing.** Disponível em: <[www.definiens.com/documentation](http://www.definiens.com/documentation)>. Acesso em Nov. 2001.

SCHNEIDER W, STEINWENDNER, J. **Landcover Mapping By Interrelated Segmentation And Classification Of Satellite Images.** International Archives of

Photogrammetry and Remote Sensing, Vol. 32, Part 7-4-3 W6, Valladolid, Spain, 3-4 June, 1999

SCHWARZ, M, STEINMEIER & WASER, M. **Detection of storm losses in alpine forest areas by different methodic approaches using high-resolution satellite data.** Swiss Federal Research Institute, WSL. Disponível em : <[www.defeniens.com/publication.pdf](http://www.defeniens.com/publication.pdf)> Acesso em dez 2001.

SEBE, N; LEW, M. **Wavelet based in textute classification.** 15<sup>th</sup> Conference pattern Recognition, vol 3, 961pp. Barcelona. 2000.

SIMPSON , J.J.& KELLER, R.H. **An improved fuzzy logic segmentation of sea ice, clouds, and ocean in remotely sensed arctic imagery.** In Remote Sensing for Environment. p.291-331. 1995.

SOLBERG, Anne et al. **A Markovv Random Field model for classification of multisource Satellite Imagery.** IEEE Transations on Geosciences and Remote Sensing, Vol 34, January. 1996.

SOWA, John F. **Knowledge Representation: Logical, Philosophical, and Computational Foundations,** Brooks/Cole Publishing Co., Pacific Grove, CA. 2000.

STEHMAN,S,CZAPLEWSKI,R. **Design and Analysis for Thematic Map Accuracy Assessment: Fundamental Principles.** Remote Sensing of Environment. Vol 2.1988.

TILTON, J. **Hierarchical Image Segmentation:as applied to Remotely Sensed Multispectral or Hyperspectral Imagery.** NASA Applied Information Sciences Branch. Disponível em [www.backserv.gsfc.nasa.gov/code935/tilton](http://www.backserv.gsfc.nasa.gov/code935/tilton) . Acesso em abril 2002.

TON, Jezching et al. **Knowledge-based segmentation of Landsat images.** IEEE Transactions on Geosciences and Remote Sensing. Vol 29. nº 1, março. 1991.

TOWNSEND, P. A. **A quantitative fuzzy approach to assess mapped vegetation classification for ecological applications.** Remote Sensing of Environment, 72, p.253– 267. 2000.

USERY, L. E. **A Conceptual framework and fuzzy set implementation for geographic features.** In Geographic Objects with Indeterminate Boundaries. Gisdata 2. Taylor & Francis. 1996

VICENTE P.P et al. **Sistemas Inteligentes : aplicações em recursos hídricos e ciências ambientais.** ABRH. UFRS. Porto Alegre . 1999.

VIEIRA, P.V et al. **Sistemas inteligentes: aplicações em recursos hídricos e ciências ambientais**. UFRS.ABRH. Porto Alegre. 1999.

VORWERG, C., RICKHEIT , G. **Typicality effects in categorization of special relations** . In Spatial Cognition an interdisciplinary approach to representing and processing spational knowledge. Springer. Berlin. p.203-222. 1998

WACKERNAGEL, H. **Multivariate Geostatistic**. Springer. Revised 2<sup>nd</sup> edition.Berlin. 1995.

WANG, F. **Improving remote sense image analysis trough fuzzy information representation**. Photogrammetric Engineering and Remote Sensing, vol.56, p.1163-1169. 1990a.

WANG, F. **Fuzzy supervised classification of remote sensing images..** IEEE Transactions on Geoscience and Remote Sensing. vol.28, p.194-201. 1990b.

WILLHAUCK, G. **Comparison of objected oriented classification techniques and standard image analysis for use of change detection between Spot a multispectral satellite images and aerial photos**. ISPRS vol XXXXIII, Part B3. Amsterdam. 2000. 1 CD-ROM.

WILLHAUCK, G, BENZ, U, SIEGERT, F. **Semiautomatic classification procedures for FIRE monotoring using multitemporal SAR images and NOAA-AVHRR hotspot data**. Definiens digital paper. Munich 2002.

ZADEH, L. **Fuzzy Sets**. Inform. Contr. Vol 8. 338-353pp. 1965.

ZEILER, M. **Modeling our world**. Published by ESRI-Press. California,US. 2001.

ZHANG, YUN. **Optimization of building detection in satellite images by combining multiespectral classification and texture filtering**. ISPRS Journal of Photogrammetry and Remote Sensing, n° 54. 1999.

ZHOU, J. ; CIVO, L. **Using genetic learning neural networks for spacial decision making in GIS**. Photogrammetric Engineering and Remote Sensing, vol.62, p.1287-1295. 1996.



## ANEXO 1- IMAGEM IKONOS E RETIFICAÇÃO

### 1- Características da Imagem Ikonos

Altitude	680 km
Inclinação	98,1°
Velocidade	7km / s
Data	Janeiro/2001
Sentido da Órbita	Descendente
Duração da Órbita	98 minutos
Tipo de Órbita	Sol-síncrona
Resolução Espacial	Pancromática: 1m(não disponível) Multiespectral: 4m
Bandas espectrais	Azul 0.45 – 0.52 µm Verde 0.52 – 0.60 µm Vermelho 0.63 – 0.69 µm Infravermelho Próximo 0.76 – 0.90 µm
Ângulo de Visada	Rápida alternância entre diferentes ângulos
Imageamento	13km na vertical (cenas de 13kmx13km)
Capacidade de Aquisição de imagens	Faixas de 11kmx100km até 11kmx1000km Mosaicos de até 12.000km <sup>2</sup> 20.000km <sup>2</sup> de área imageada numa passagem
Frequência de Revisita	2.9 dias no modo Pancromático 1.5 dia no modo Multiespectral

Fonte: Adaptado GELACH, 2000.

### 2- Retificação

No levantamento GPS da área de estudo, utilizou-se o método de posicionamento relativo. Foram levantados 20 pontos de controle, utilizando-se no levantamento o modo de posicionamento estático rápido.

A imagem IKONOS, originalmente em WGS84, foi transformada para o referencial Córrego Alegre. Uma vez estando no mesmo sistema de referência dos pontos de controle, pode-se comparar a imagem pré-corrigida com o levantamento GPS.

A imagem foi corrigida por meio de polinômio 2º sem a utilização modelo numérico do terreno, pois o relevo era pouco acidentado.

Na correção geométrica, definiram-se os métodos: de transformação polinomial de 2º ordem e de reamostragem pelo vizinho mais próximo.

$X' = a_0 + a_1x + a_2y + a_3xy + a_4x^2 + a_5y^2$	$Y' = d_0 + d_1x + d_2y + d_3xy + d_4x^2 + d_5y^2$
----------------------------------------------------	----------------------------------------------------

Equação Polinomial de 2º ordem utilizada na transformação

Onde: X' e Y' representam as coordenadas na imagem não corrigida pelo sistema de matriz das coordenadas georreferenciadas (x,y); a<sub>0</sub>, a<sub>1</sub>, a<sub>2</sub>, a<sub>3</sub>, a<sub>4</sub>, a<sub>5</sub>, d<sub>0</sub>, d<sub>1</sub>, d<sub>2</sub>, d<sub>3</sub>, d<sub>4</sub>, d<sub>5</sub> representam os parâmetros de transformação.

Foi determinado que a imagem registrada apresentaria os seguintes parâmetros: projeção UTM, *datum* Córrego Alegre, zona 22 e hemisfério Sul.

Foram identificados 20, porém foram escolhidos somente 11 PC's, onde sua geometria atendeu toda área, possibilitando um ajuste no qual o *rms* mínimo alcançado foi de **4,2969 metros**, ou seja, aproximadamente um pixel. Esta a acurácia obtida atendeu ao objetivo do trabalho.

## ANEXO 2- ÍNDICES DE ACURÁCIA

A avaliação da acurácia pode ser obtida por meio de coeficientes de concordância, sendo que estes podem ser expressos como concordância total ou para classes individuais. Alguns dos coeficientes de concordância comumente usados para avaliar a acurácia total do mapa temático estão apresentados na Tabela 1.

*Kappa* é definido como um coeficiente de concordância para escala nominais que pede a proporção de concordância depois que a concordância atribuída à casualidade é retirada de consideração. O coeficiente *Kappa* considera todos os elementos da matriz de erros ao invés de apenas aqueles que se situam na diagonal principal da mesma, ou seja, estima a soma da coluna e linha marginais. Similarmente a *Kappa*, o coeficiente *Tau* mede o grau de concordância em escalas nominais assumindo que :

- As unidades são independentes;
- As classes ou categorias da escala nominal são independentes e mutuamente exclusivas;
- O classificador e os pontos de referência operam de forma independente.

TABELA 1: COEFICIENTES DE CONCORDÂNCIA PARA A AVALIAÇÃO DA ACURÁCIA TOTAL.

Acurácia	Fórmula	Interpretação
Concordância Total	$P_o = \frac{\sum X_{ii}}{N}$	$0 \leq P_o \leq +1$
Coeficiente de concordância <i>Kappa</i>	$\kappa = \frac{P_o - P_e}{1 - P_e}$	$-1 \leq \kappa \leq +1$
Coeficiente de Concordância <i>Tau</i>	$\tau = \frac{P_o - P_r}{1 - P_r}$	$-1 \leq \tau \leq +1$

FONTE: Adaptado de ANTUNES & LINGNAU, 1997

$P_o$  para toda a matriz de erros é dado pela razão do somatório da diagonal principal ( $\sum X_{ii}$ ) pelo número total de observações ( $N$ ).  $P_o$  pode ser traduzido pela proporção de unidades (pontos de referência) que concordam.  $P_e$  é expresso pelo somatório do produto dos elementos das linhas e colunas marginais ( $\sum X_{i+} X_{+i}$ ) pelo número total de observações ao quadrado.  $P_e$  traduz a proporção de elementos atribuído a determinada classe ao acaso. O valor positivo de *Kappa* sugere que o valor observado de concordância é maior que a concordância ao acaso esperada. O valor  $\kappa = 1$  ocorre quando houver total concordância entre os pontos de referência e as categorias classificadas.

O coeficiente de concordância *Tau* baseia-se na probabilidade a priori (NAESSET, 1996), ou seja, a concordância esperada ( $P_r$ ) pode ser obtida antes mesmo de elaborar a matriz de erros.  $P_r$  é expresso por  $1/k$ , onde  $k$  é número de categorias ou classes. Pode ser considerado, ainda, se a classificação das categorias foi efetuada com a mesma probabilidade ou não (MA & REDMOND, 1995, NAESSET, 1996). Sua interpretação é feita da mesma forma do que coeficiente *Kappa*.

Considerando  $\tau$  condicional, ou seja, não mais  $1/k$ , então,  $\Pr$  seria dado por:

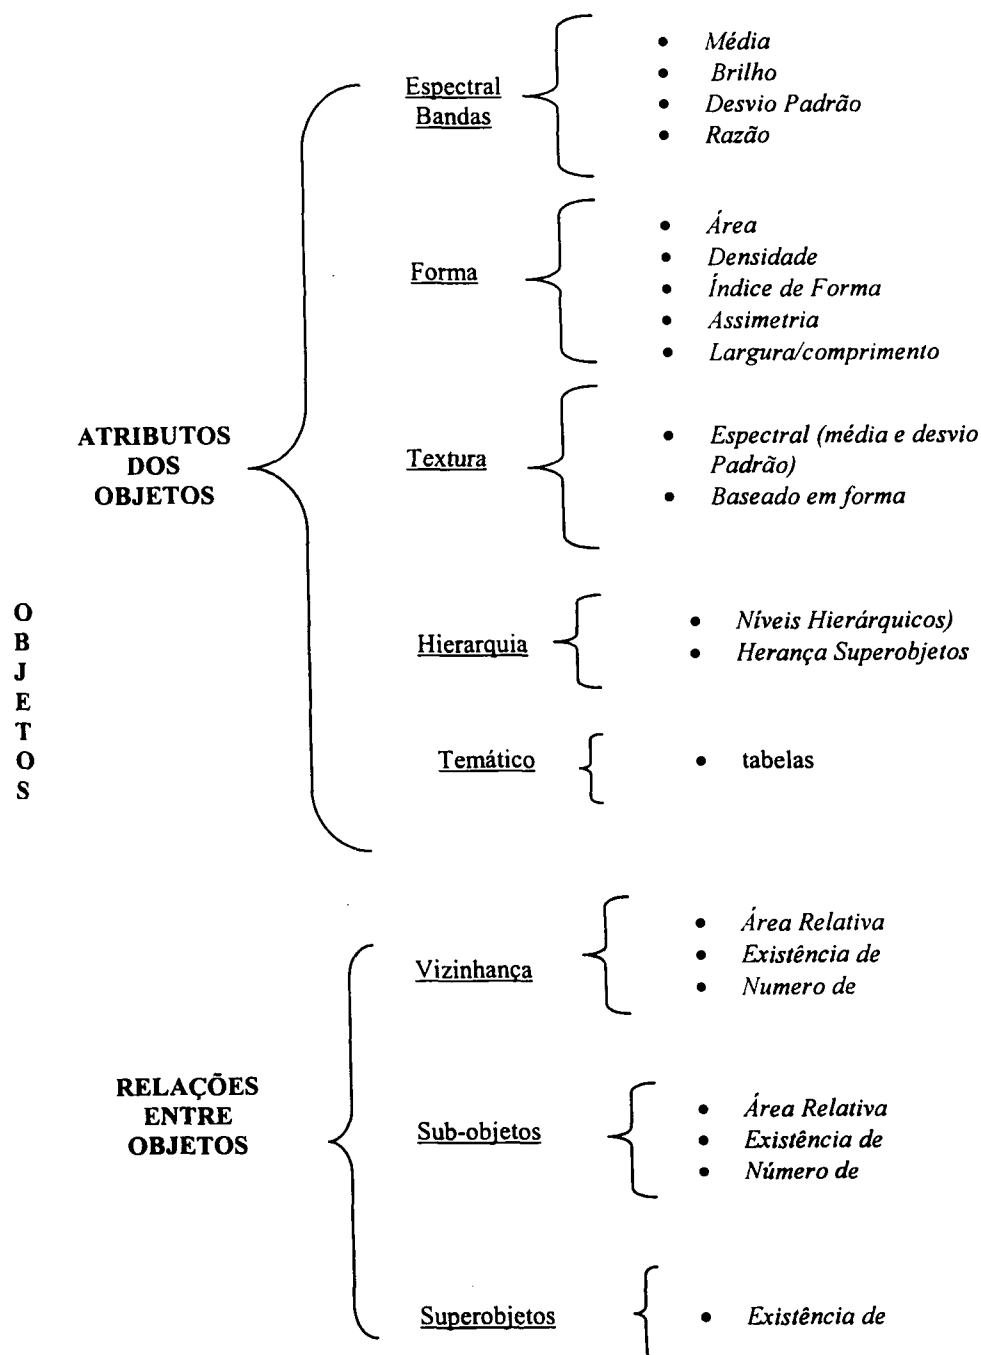
$\Pr = \sum_{i=1}^r X_i + / n_i$ ; que representa a probabilidade a priori diferenciada a cada classe. Indica a probabilidade que uma categoria classificada (mapa/imagem) representasse a mesma categoria no campo.

De acordo com estudos realizados por NAESET (1996)  $\tau$  condicional apresenta resultados muito próximos a expressão da probabilidade a priori expressa pelo número de categorias.

Conceitualmente  $\tau$  é mais fácil de ser interpretado que  $\kappa$ . A concordância ao acaso ( $\Pr$ ) usada no cálculo de  $\tau$  é a medida direta de pertinência ao acaso.  $\tau$  também possui um certo grau de independência da matriz de erros, pois  $\Pr$  é determinado antes mesmo da matriz ser montada (MA & REDMOND, 1995, NAESET, 1996, ANTUNES & LINGNAU, 1997). Talvez estas características sejam mais apropriadas numa avaliação preliminar da acurácia de imagens temáticas oriundas de classificadores leves.

## ANEXO 3- DESCRITORES DOS OBJETOS

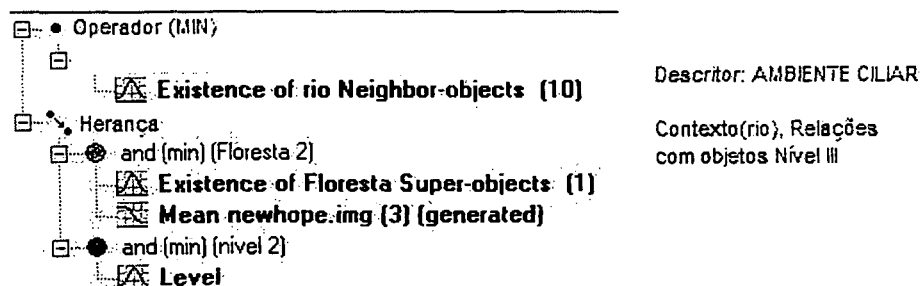
No esquema abaixo são apresentadas as principais características dos objetos que permitem obter parâmetros descritores. Descritores compõem os pontos notáveis da função de pertinência fuzzy. A classificação de um objeto pode, também, depender de relações contextuais entre objetos. Este esquema mostra os possíveis descritores e as relações entre objetos relevantes à classificação orientada a objeto.




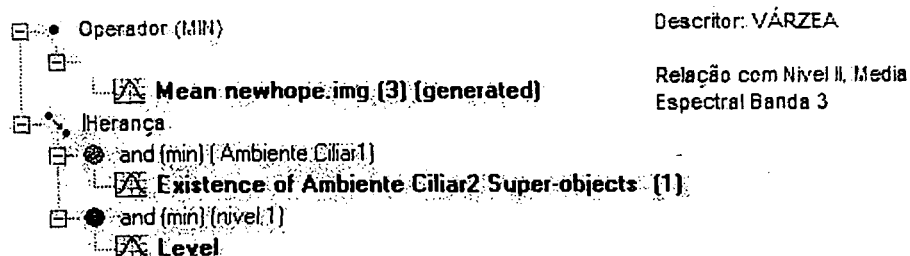
## ANEXO 4- SINTAXE DAS REGRAS FUZZY

Abaixo são apresentados exemplos de sintaxe de regras fuzzy para discriminação de algumas classes. Além de utilização dos descritores de forma e espectral são também utilizadas as relações entre os objetos (*existência\_de*).

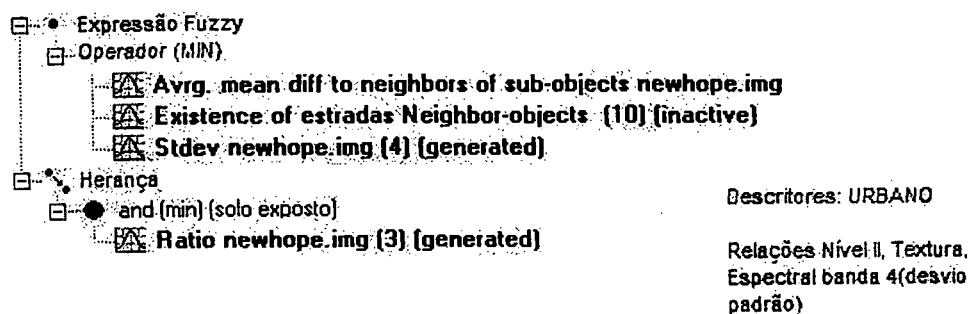
### Supérobjetos, Nível II



### Sub-objetos, Nível I



### Superobjetos Nível I



## ANEXO 5- RESULTADO DA CLASSIFICAÇÃO ORIENTADA A OBJETO

### USO DO SOLO: NOVA ESPERANÇA-PR



- Legenda**
- Cana
  - Capoeirinha
  - Lago
  - Eucalipto
  - Floresta
  - Mata de Galeria
  - Outras Culturas
  - Pastagem
  - Solo Exposto
  - Solo Urbano
  - Várzea
  - Rio

1 0 1 Kilometers

Imagem classificada a partir de imagem Ikonos  
Janeiro 2001



## ANEXO 6- ACURÁCIA DA INTERPRETAÇÃO

Geralmente a acurácia de mapas provenientes de fotointerpretação é aceita como adequada sem que haja uma confirmação com dados coletados em campo. Não obstante, muito raramente a interpretação é totalmente correta. Se os pontos de referencia são baseados da interpretação visual da imagem original, se faz mister também avaliar se a interpretação é confiável.

Coletou-se em campo 50 pontos de controle temático para diferentes classes (Paraná 12 meses). As amostras foram coletadas de forma aleatória para um conjunto de categorias. A avaliação da acurácia da interpretação é baseada no método proposto por HORD & BROONER (1976), RICHARDS (1997), CONGALTON (1999) que apresentaram a expressão do cálculo do intervalo de confiança para uma amostra  $n$ :

$$p\{-Z_{\alpha/2} < x - n\theta / \sqrt{n\theta(1-\theta)} < Z_{\alpha/2}\} = 1 - \alpha$$

onde:

$x$  é o número de objetos corretamente identificados;

$n$  é o tamanho da amostra;

$\theta$  é a acurácia total da identificação  $x/n$ ;

$1-\alpha$  é o limite de confiança.

Visto que a amostragem possuía mais que 30 pontos, considerou-se a distribuição normal dentro de uma certeza 95%.

No caso em questão teve-se:

$n= 50$  (pontos amostrados);

$x= 45$  (pontos corretamente identificados);

$\theta=0,90$  (probabilidade de acerto);

$Z_{\alpha/2}= 1,96$  (tabelado)

$\alpha = 0,05$  (limite de confiança)

Isolando  $\theta$ , tem-se:  $\left(x + 1,921 \pm 1,96 \sqrt{(x(n-x) / (n + 0,96))} + (n + 3,842)\right)$ , substituindo os valores de  $n$  e  $x$  se obtém  $\theta$  para o seguinte intervalo de confiança (ic):

$$\theta_{ic} = (44,92 \pm 3,64) / 50,84.$$

Como resultado, conclui-se que a acurácia está compreendida num intervalo de confiança de [95,55 , 81,20%] com 95% de certeza. Sendo que ,  $\theta = x/n = 90\%$  está compreendido neste intervalo. A acurácia média ( $\theta_m$ ) é dada pelo valor central do intervalo, de **88,37 %**. Considerou-se, então, a interpretação como válida como referencia a matriz de erros.